

ELVÉCIO GOMES DA SILVA JÚNIOR

REDES NEURAS ARTIFICIAIS PARA PREVISÃO DE QUALIDADE DE FIBRA
DO ALGODOEIRO (*Gossypium hirsutum* L.)

Dissertação apresentada à Universidade Federal de
Uberlândia, como parte das exigências do Programa de Pós-
graduação em Agronomia – Mestrado, área de concentração
em Produção Vegetal, para obtenção do título de “Mestre”.

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

UBERLÂNDIA
2022

ELVÉCIO GOMES DA SILVA JÚNIOR

REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE QUALIDADE DE FIBRA
DO ALGODOEIRO (*Gossypium hirsutum* L.)

Dissertação apresentada à Universidade Federal de
Uberlândia, como parte das exigências do Programa de Pós-
graduação em Agronomia – Mestrado, área de concentração
em Produção Vegetal, para obtenção do título de “Mestre”.

APROVADA em 30 de novembro de 2022.

Banca Examinadora:

Prof.^a Dr.^a Ana Paula Oliveira Nogueira (UFU/ICIAG)

Prof. Dr. João Paulo Ribeiro Oliveira (UFU/ICIAG)

Dr. Murilo Ferraz Tosta (UFLA)

Prof.^a Dr.^a Larissa Barbosa de Sousa (UFU/ICIAG)

UBERLÂNDIA
2022



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



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agronomia				
Defesa de:	Dissertação de Mestrado Acadêmico, 018/2022, PPGAGRO				
Data:	Trinta de novembro de dois mil e vinte e dois	Hora de início:	09:20	Hora de encerramento:	11:40
Matrícula do Discente:	12012AGR006				
Nome do Discente:	Elvécio Gomes da Silva Júnior				
Título do Trabalho:	Redes neurais artificiais para previsão de qualidade de fibra do algodoeiro (<i>Gossypium hirsutum</i> L.)				
Área de concentração:	Produção Vegetal				
Linha de pesquisa:	Melhoramento de Plantas				

Reuniu-se no Anfiteatro do Bloco 2A, Campus Umuarama, da Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agronomia, assim composta: Professores Doutores: Ana Paula Oliveira Nogueira - UFU; João Paulo Ribeiro Oliveira - UFU; Murilo Ferraz Tosta - Microbiol Indústria e Comércio LTDA; Larissa Barbosa de Sousa - UFU orientadora do candidato.

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

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

Aprovado.

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

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

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



Documento assinado eletronicamente por **Larissa Barbosa de Sousa, Professor(a) do Magistério Superior**, em 30/11/2022, às 12:47, 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 **João Paulo Ribeiro de Oliveira, Professor(a) Visitante do**



Magistério Superior, em 30/11/2022, às 13:56, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Ana Paula Oliveira Nogueira, Professor(a) do Magistério Superior**, em 30/11/2022, às 20:41, 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 **Murilo Ferraz Tosta, Usuário Externo**, em 01/12/2022, às 18:45, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4098592** e o código CRC **4E5EC65D**.

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

N244 Silva Júnior, Elvécio Gomes da, 1994-2022
Redes neurais artificiais para previsão de qualidade de fibra do algodoeiro
(*Gossypium hirsutum* L.) [recurso eletrônico] / Elvécio Gomes da Silva
Júnior. - 2022.

Orientador: Larissa Barbosa de
Sousa.

Dissertação (Mestrado) - Universidade Federal de
Uberlândia, Pós-graduação em Agronomia.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.di.2022.333>

Inclui bibliografia.

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

CDU: 631

Bibliotecários responsáveis pela estrutura de acordo com o
AACR2: Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074

DADOS CURRICULARES DO AUTOR

Elvécio Gomes da Silva Júnior, nascido em Uberlândia, Minas Gerais, em três de maio de 1994. Graduado em Agronomia pela Universidade Federal de Uberlândia (UFU) em 2017. Durante a Graduação realizou estágio no Programa de Melhoramento Genético do Algodoeiro (PROMALG – UFU), sob orientação da Prof.^a Larissa Barbosa de Sousa, sendo bolsista de iniciação científica tecnológica UFU/FAPEMIG em 2013/2015. Em 2020 iniciou o Mestrado no Instituto de Ciências Agrárias (ICIAG), Universidade Federal de Uberlândia (UFU), no Programa de Pós-Graduação em Agronomia (Produção Vegetal), sob orientação da Prof.^a Dr.^a Larissa Barbosa de Sousa (UFU).

A Deus, minha força e fortaleza, que ilumina, rege e abençoa meus passos. A minha esposa Ana Flávia, meus pais Elvécio e Rosângela, minha sogra Maria Aparecida e meu cunhado Gustavo, e minha irmã Ana Livia pela força e incentivo para com o término deste trabalho.

DEDICO.

AGRADECIMENTOS

À Deus, pela força, paciência e sabedoria;

À minha esposa Ana Flávia pela paciência, amor, companheirismo e ajuda nas avaliações dos meus experimentos;

À Universidade Federal de Uberlândia (UFU), especialmente ao Programa de Pós-Graduação em Agronomia, por tornar possível a obtenção do título de Mestre;

À Associação Mineira dos Produtores de Algodão (AMIPA) por ceder os dados do ensaio;

À Prof.^a Dr.^a Larissa Barbosa de Sousa pela paciência e apoio em me orientar, principalmente nesses tempos de pandemia;

Ao colega Dr. Daniel Bonifácio pela amizade incrível e agradável convivência;

Por fim, a todos que ajudaram diretamente ou indiretamente na condução desse trabalho, meu muito obrigado!

SUMÁRIO

RESUMO	2
ABSTRACT	3
1. INTRODUÇÃO	4
2. REVISÃO DE LITERATURA	4
2.1 Importância da Qualidade de Fibra para o Sistema de Produção	4
2.2 Classificação Instrumental da Fibra do Algodão	6
2.3 Temperatura e Água na Qualidade de Fibra	7
2.4 Uso de Redes Neurais Artificiais na cultura do algodoeiro	8
3. MATERIAL E MÉTODOS	9
3.1 Local do experimento e coletas de amostras	9
3.2 Características de fibra utilizadas	12
3.3 Análises estatísticas	12
4. RESULTADOS	15
4.1 Análise prévia dos fardos processados e sua qualidade de fibra	15
4.2 Análise do coeficiente de correlação de Pearson	24
4.3 Predição de UNICIDEAL usando modelo RNAs	32
4.4 Predição de COMPIDEAL usando modelo RNAs	32
4.5 Predição de RESIDEAL usando modelo RNAs	33
5. DISCUSSÃO	33
REFERÊNCIAS	35

REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE QUALIDADE DE FIBRA DO ALGODOEIRO (*Gossypium hirsutum* L.)

RESUMO - A formação e regulação da qualidade da fibra do algodoeiro sempre foi um importante campo de pesquisa para melhorar a qualidade da fibra, commodities e valor de mercado da cultura. Uniformidade, comprimento, resistência e micronaire representam os fatores mais importantes da qualidade de fibra do algodoeiro. A temperatura e precipitação em abundância ou deficiência estão entre os mais importantes fatores chave que afetam a qualidade da fibra. No presente estudo, utilizamos diferentes arquiteturas de redes neurais artificiais (RNA) para explorar os efeitos de temperatura ambiente e precipitação sobre a qualidade de fibra do algodoeiro, com base em 5 cultivares (TMG 44 B2RF, FM 983 GLT, FM 906 GLT, FM 985 GLTP, FM 911 GLTP), além de 11.042 amostras de HVI (*High Volume Instrument*) da safra 2020/21, no município de Coromandel, Minas Gerais. Os resultados mostram que o modelo de RNA com a estrutura de 12–12–1 pode prever resistência da fibra com alta precisão ($R^2 = 0,90$), o modelo RNA com a estrutura de 10–11– 1 pode prever o comprimento da fibra com a maior precisão ($R^2 = 0,91$), e o modelo RNA com a estrutura de 9–10–1 pode prever a uniformidade de fibra com a mais alta precisão ($R^2 = 0,95$). As previsões dos modelos de rede neural artificial estabelecidas podem melhorar a qualidade da fibra do algodoeiro produzida na propriedade otimizando de acordo com cultivar, além da temperatura e precipitação monitoradas.

Palavras-chave: *Gossypium hirsutum*; qualidade de fibra; rede neural artificial.

ARTIFICIAL NEURAL NETWORKS IN PREDICTING COTTON FIBER QUALITY (*Gossypium hirsutum* L.)

ABSTRACT - The formation and regulation of cotton fiber quality has always been an important field of research to improve fiber quality, commodities and market value of the crop. Uniformity, length, resistance and micronaire represent the most important factors of cotton fiber quality. Temperature and precipitation in abundance or deficiency are among the most important key factors that affect fiber quality. In the present study, we used different artificial neural network (ANN) architectures to explore the effects of ambient temperature and precipitation on cotton fiber quality, based on 5 cultivars (TMG 44 B2RF, FM 983 GLT, FM 906 GLT, FM 985 GLTP, FM 911 GLTP), in addition to 11,042 HVI (High Volume Instrument) samples from the 2020/21 crop season, in Coromandel, Minas Gerais state. The results show that the ANN model with the 12–12–1 structure can predict fiber strength with high accuracy ($R^2 = 0.90$), the ANN model with the 10–11–1 structure can predict fiber length. fiber with the highest accuracy ($R^2 = 0.91$), and the ANN model with the structure of 9–10–1 can predict fiber uniformity with the highest accuracy ($R^2 = 0.95$). Predictions from established artificial neural network models can improve the quality of cotton fiber produced on the property by optimizing according to cultivar, in addition to monitored temperature and precipitation.

Palavras-chave: Artificial neural networks; fiber quality; *Gossypium hirsutum*.

1. INTRODUÇÃO

O *Gossypium hirsutum* é a espécie de algodão mais cultivada no mundo. A planta foi domesticada há mais de milhares de anos no sul da Arábia, e como consequência deste processo incessante de domesticação, o algodão é a fibra de origem vegetal mais importante na indústria têxtil do mundo (COTTON INCORPORATED, 2022).

A qualidade da fibra do algodão é determinada principalmente por fatores genéticos e morfológicos das plantas, além de também ser afetada por fatores climáticos, principalmente temperatura e água. Além disso, o processo de colheita e de beneficiamento também têm papel fundamental na manutenção da qualidade da fibra obtida no campo (SALGADO et al., 2015).

A alta qualidade da fibra do algodoeiro é fator primordial para que o algodão tenha uma boa aceitação no mercado externo e interno, afetando diretamente sua comercialização. Com isso, as avaliações da qualidade, estão cada vez mais rigorosas e são executadas por laboratórios, que a cada dia apresentam maior qualificação (CARDOSO et al., 2015; CARDOSO et al., 2019).

Uma estratégia que tem sido amplamente utilizada nos programas de melhoramento para avaliar a qualidade de fibra é o emprego da análise de fibra feita pelo HVI (*High Volume Instrument*). Nesse contexto, a modelagem matemática surge como uma ferramenta auxiliar na melhoria da qualidade de fibra produzida no campo, auxiliando a classificação dos genótipos e indicação de cultivares. As redes neurais artificiais (RNA's) são um conceito da computação que visa trabalhar o processamento de dados de maneira semelhante ao cérebro humano, adquirindo conhecimento através da experiência, possibilitando prever algo, reconhecer padrões ou estabelecer agrupamentos (HAYKIN, 2008; BRAGA et al., 2011; HUANG et al., 2021).

Diante dos desafios na produção de fibra de algodão de alta qualidade, o objetivo deste estudo foi verificar a correlação entre temperatura média e pluviosidade na época de plantio de 5 cultivares diferentes cultivados na safra 2020/21, no município de Coromandel, e parâmetros da qualidade intrínseca da fibra do algodoeiro e prever com o uso de redes neurais artificiais valores ideais para maximizar a qualidade de fibra produzida nesta propriedade.

2. REVISÃO DE LITERATURA

2.1 Importância da qualidade de fibra para o sistema de produção

A qualidade da fibra do algodão é determinada por diversos fatores, dentre os quais, destacam-se: fatores genéticos e morfológicos das plantas, fatores climáticos, aspectos agronômicos (nutricionais, fitossanitários e condução de lavoura). O processo de colheita e de beneficiamento têm papel fundamental na manutenção da qualidade da fibra obtida no campo. O interesse do produtor em obter fibra de alta qualidade se inicia antes mesmo do plantio da lavoura, com a escolha das variedades a serem cultivadas. Programas de melhoramento genético do algodoeiro que sempre visaram o incremento da produtividade e rendimento de pluma aliados à outros avanços tecnológicos têm permitido aos produtores brasileiros alcançar patamares produtivos nunca alcançados (CONAB, 2022).

Vários parâmetros são considerados visando a qualidade da fibra do algodoeiro. O comprimento de fibra é o carácter de fibra do algodão mais importante, determinando a quantidade de fibras que podem sobrepostas entre si. Quanto maior a sobreposição, mais fibras se ligam, o que aumenta a resistência do fio (KHADDAM; AHMAD, 2022).

A finura da fibra, estimada pelo índice micronaire, é outro parâmetro importante para o melhoramento visando a resistência do fio. Quanto melhor a finura do fio de algodão, mais fibras por seção transversal são utilizadas, resultando em maior resistência do fio. Discutindo sobre as influências de diversos parâmetros de qualidade de fibra, Broughton et al. (1992) reconheceram que o aumento do comprimento de fibra gera uma maior resistência do fio ao atrito por alguma força externa. O comprimento e resistência da fibra têm sido diretamente influenciados pelo processamento têxtil e provavelmente continuarão sendo aprimorados devido aos avanços tecnológicos cada vez mais constantes na indústria, como por exemplo, a velocidade de urdido (KOHEL, 1999; AMJAD, 1999; LIMA; BELOT, 2020).

Nas safras de 1990/91 até 1998/99, valores de uniformidade do comprimento da fibra abaixo de oitenta por cento eram comuns na grande maioria dos materiais, sendo essa situação compartilhada por outros países como Argentina, Bolívia e Paraguai (SANTANA et al., 1998). No entanto, a indústria têxtil não aceita atualmente valores inferiores à 82 por cento, comumente encontrados nas análises HVI para a grande maioria dos cultivares comercializados. Os padrões de resistência de fibra também foram elevando-se ao longo das safras, encontrando-se valores de 22 a 33 g tex⁻¹ atualmente (COUTINHO, ANDRADE, PEGORARO, 2015; CARVALHO et al., 2015). Como resultado desses esforços conjuntos, a cotonicultura no Brasil se tornou mais competitiva, se tornando o primeiro país em produtividade em sequeiro (ABRAPA, 2022).

2.2 Classificação instrumental da fibra do algodão

Os critérios que definem a compra de uma matéria prima pela indústria têxtil são estabelecidos a partir da relação custo e benefício da fibra a ser adquirida. Os lotes que atendem os padrões exigidos por cada indústria têxtil são mais bem avaliados e pagos conforme a qualidade que atingirem. Para determinar se uma amostra segue os padrões de fibra que a indústria exige são necessárias avaliações precisas, instrumentadas e com limites bem definidos para a categorização comprovada da amostra. Entre as principais características avaliadas para a classificação de um lote está o comprimento de fibra, o índice Micronaire (finura da fibra relacionada à maturidade) e a resistência da fibra (CHANSELME, 2006). As fibras com comprimento menor dificultam a obtenção de fios de qualidade para a indústria têxtil, já as fibras imaturas não absorvem a tintura adequadamente, enquanto que fibras de baixa resistência se quebram facilmente durante a tecelagem, depreciando o valor comercial do lote (BACHELIER, 2004).

A classificação instrumental da fibra de algodão é uma determinação automática e objetiva das características importantes da fibra que de outra forma seriam impraticáveis de se avaliar visualmente. Essa classificação instrumental se dá pelo uso dos instrumentos HVI, como mencionado anteriormente, e que determinam de forma prática todas as medidas das características das fibras do algodão, como: comprimento (UHML); uniformidade do comprimento (UI); índice de fibras curtas (SFI); Micronaire (MIC); resistência (STR); alongamento (ELG); maturidade da fibra (MR); grau de cinza (RD); grau de amarelamento (+b); trash de folha (fragmentos contaminantes) e neps (neps grama⁻¹) (CHANSELME, 2006; CHANSELME, 2014). Entre os principais equipamentos que compõe um HVI, destaca-se o fibrógrafo (determina o comprimento e a uniformidade de comprimento), o Micronaire (determina a finura e a maturidade), e o estelômetro (resistência e alongamento). A seguir são comentadas as características têxteis mais importantes das fibras do algodão:

Comprimento da fibra do algodão (COMP) é realizada com uma porção, ou franja, de fibras, que é retirada da amostra representativa de um fardo, e as fibras são paralelizadas por escova rotatória. As fibras são mensuradas e o comprimento médio da metade mais longa das fibras expresso em polegadas (1/32) e milímetros.

A uniformidade de comprimento (UNIC) é a relação entre o comprimento médio das fibras totais e o comprimento médio da metade mais longa das fibras, e é expresso

em percentual. A UNIC representa a homogeneidade do comprimento das fibras do fardo e é uma inferência da qualidade da fiação.

Índice Micronaire (MICRO) é uma medição da maturidade fisiológica da fibra, e consequentemente de sua espessura. Para fibras provenientes de algodões da mesma variedade, as variações do MICRO correspondem a variações de maturidade. O índice é determinado a partir da resistência ao fluxo de ar que passa por um chumaço de fibra de massa e volume determinados. A amplitude considerada ideal para a maioria dos propósitos da fibra do algodão está entre 3,7 a 4,2. Valores de MICRO abaixo dessa amplitude indicam fibras imaturas, enquanto que valores altos são desfavoráveis à resistência do fio de fibras.

Resistência (RESI) é feita com uma franja de fibras é presa entre duas pinças espaçadas em 3,2 mm. As pinças são então separadas até o ponto de ruptura das fibras. A resistência medida pelo HVI é calculada a partir da força em gramas necessária para quebrar a franja de fibras (gramas tex⁻¹). Esta distância percorrida pelas pinças até o ponto de ruptura das fibras é utilizada para determinar o alongamento (%), que se torna outra importante característica em alguns casos.

Outras características da fibra ainda podem ser determinadas pelo HVI, como (i) o grau de cor, que procura reproduzir os resultados da classificação visual a partir da medição da reflectância (Rd, %) e do índice de amarelamento (+b); (ii) as impurezas (trash), que é o percentual da amostra coberta por partículas de matéria estranha escura (folha, fragmentos de caroço, fibras de caules, etc.). Um valor de trash de 1.5 indica que as partículas escuras representam 1,5% da área da amostra avaliada; (iii) a taxa de fibras curtas (SFC ou SFI) representa a quantidade de fibras com comprimento inferior a 12,7 mm (% da massa da amostra); (iv) o número de neps, que determina a quantidade de nós que os feixes de fibra apresentam por grama da amostra, sendo esta característica, e a taxa de fibras curtas, fortemente determinadas pelos processos de beneficiamento; e (v) o índice de consistência (SCI) que é uma característica calculada do conjunto de outras tantas variáveis, e um parâmetro para a indústria têxtil determinar os melhores índices de produtividade (CHANSELME, 2014).

2.3 Temperatura e água na qualidade de fibra

A temperatura é um importante fator por afetar nas características da fibra. Segundo Krieg e Hequet (2005), o aumento da temperatura pode favorecer o grau de

deposição de celulose nas fibras do algodoeiro, se relacionando à resistência das mesmas. Em relação ao comprimento da fibra, a temperatura tem função variável, estando as influências das temperaturas mínimas ou noturnas mais ligadas a esse fator. Bradow e Davidonis (2010) evidenciam que, para o comprimento máximo da fibra, as temperaturas noturnas devem estar entre 19 °C e 20 °C. As temperaturas médias durante a formação das maçãs devem estar abaixo de 25 °C (REDDY et al., 1999). Já as temperaturas máximas devem estar entre 30 °C e 35 °C, sendo que, ao estudar o efeito dessas temperaturas no comprimento da fibra, foi observada uma correlação linear negativa. Então, o aumento da temperatura máxima reduziu de forma significativa os valores do comprimento da fibra do algodão (YEATES, 2014).

A água se associa à temperatura, uma vez que uma das funções da água é a da manutenção da temperatura do dossel das plantas. No caso do algodoeiro, cerca de 95% da água absorvida é utilizada para o resfriamento da planta, mantendo a temperatura das folhas no limite ideal (23,5 °C a 30 °C) e favorecendo a atividade enzimática. Neste sentido, durante o processo fotossintético, quando a transpiração da água é reduzida, principalmente nas folhas, a energia não dissipada durante a evaporação aquece o tecido das plantas. Uma estratégia é a adoção da irrigação, mas no Centro Oeste não é observado o uso potencial dessa técnica, uma vez que aumenta o custo de produção.

Segundo Sousa et al. (2009) essa técnica possibilita a diminuição da incerteza climática no cultivo de sequeiro, definindo-se quando e quanto irrigar se baseando no desenvolvimento da cultura, para que as necessidades das plantas possam ser atendidas. Além do resfriamento da planta, a água é importante para criar pressão de turgescência (expansão das células e enrijecimento das estruturas das plantas), é solvente para possibilitar a absorção dos nutrientes do solo e componente de processos bioquímicos, com ênfase na fotossíntese (YEATES, 2014).

2.4 Uso de redes neurais artificiais na cultura do algodoeiro

As redes neurais artificiais (RNA's) são um conceito da computação que visa trabalhar o processamento de dados de maneira semelhante ao cérebro humano, adquirindo conhecimento através da experiência, possibilitando prever algo, reconhecer padrões ou estabelecer agrupamentos (HAYKIN, 2008; BRAGA et al., 2011). Na cultura do algodoeiro as RNA's tem sido empregadas em estudos de diversidade genética (BARBOSA et al., 2011), predição de valor genético (SILVA et al., 2014) e análises de

adaptabilidade e estabilidade (BARROSO et al., 2013; NASCIMENTO et al., 2013), além da utilização para classificação de genótipos segundo cor e produtividade (SILVA JUNIOR et al., 2017; CARDOSO et al., 2019). No algodoeiro foram utilizadas principalmente em estudos de predição de algumas características relacionadas a fiação na indústria têxtil e algodão cardado (JACKOWSKA-STRUMILLO et al., 2004; GHOSH et al., 2005; UREYEN; KADOGLU, 2007; GHAREHAGHAJI et al., 2007; HAGHVERDI et al., 2018; KHADDAM; AHMAD, 2022; ABD-ELHAMIED et al., 2022).


Um dos principais atributos da técnica de RNA's está em sua estrutura não linear aliada à sua capacidade de não requerer informações detalhadas sobre os processos físicos do sistema a ser modelado (XU et al., 2021). Como método de classificação, as RNA's apresentam certas vantagens, como a de ser não paramétrica e serem tolerantes a perda de dados (GOH et al., 2021).

3. MATERIAL E MÉTODOS

3.1 Local do experimento e coletas de amostras

O estudo experimental foi realizado em talhões comerciais de algodoeiro, no município de Coromandel, Minas Gerais, localizado na latitude 18°12'19.0"S e longitude 47°11'45.0"W (Figura 1).

Figura 1. Localização da Fazenda São Miguel, no município de Coromandel, Minas Gerais, onde foram retiradas as amostras de fibra em talhões comerciais.



Foram selecionados 4.150 fardos do cultivar FM 983 GLT, 2.502 fardos do cultivar FM 906 GLT, 1.564 fardos do cultivar FM 985 GLTP, 1.450 fardos do cultivar

TMG 44 B2RF e 1.376 fardos do cultivar FM 911 GLTP para análise das características intrínsecas da fibra, obtidas com auxílio do aparelho HVI (*High Volume Instrument*). Uma amostra por fardo foi utilizada para obtenção da qualidade da fibra do algodoeiro.

Em cada talhão, foram coletadas temperatura máxima e mínima para a obtenção da temperatura média do ar e precipitação pluviométrica desde o dia 01/12/2021 até o dia 31/01/2022, conforme os mapas nas figuras 2 e 3, por meio de uma estação meteorológica automatizada.

Figura 2. Representação gráfica da temperatura média da propriedade nos meses de Dezembro/2021 (A) e Janeiro/2022 (B).

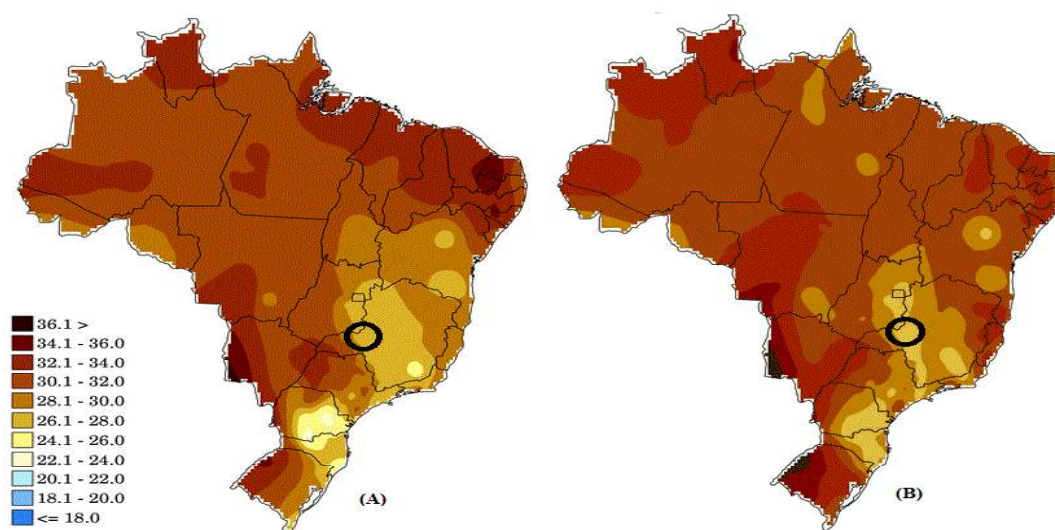
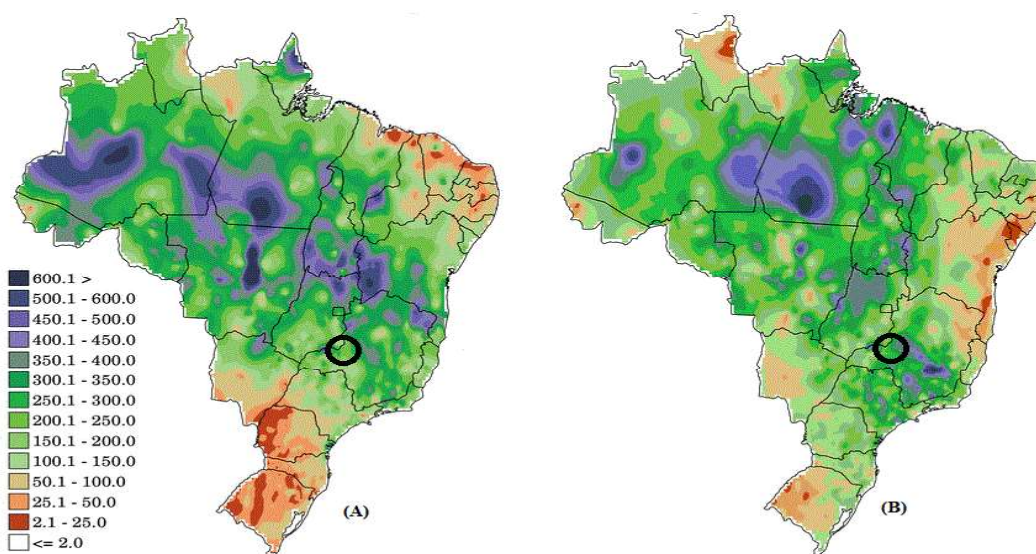


Figura 3. Representação gráfica da precipitação média da propriedade nos meses de Dezembro/2021 (A) e Janeiro/2022 (B).



As anomalias de temperatura e pluviosidade em relação à média histórica foram analisadas e não foram retiradas dos dados obtidos (Figura 4 e 5). Os dados

meteorológicos de precipitação pluviométrica e temperatura média do ar foram obtidos por meio do banco de dados da estação meteorológica da fazenda. Esses dados foram utilizados como fonte de variação nos modelos testados.

Figura 4. Representação gráfica da anomalia da temperatura média da propriedade nos meses de Dezembro/2021 (A) e Janeiro/2022 (B).

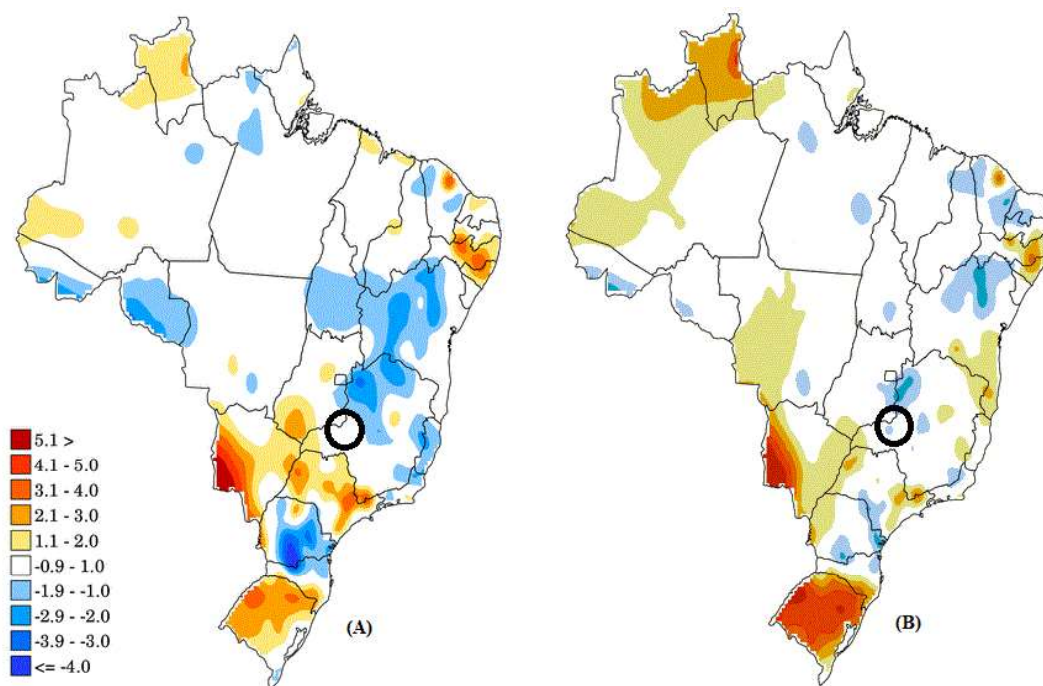
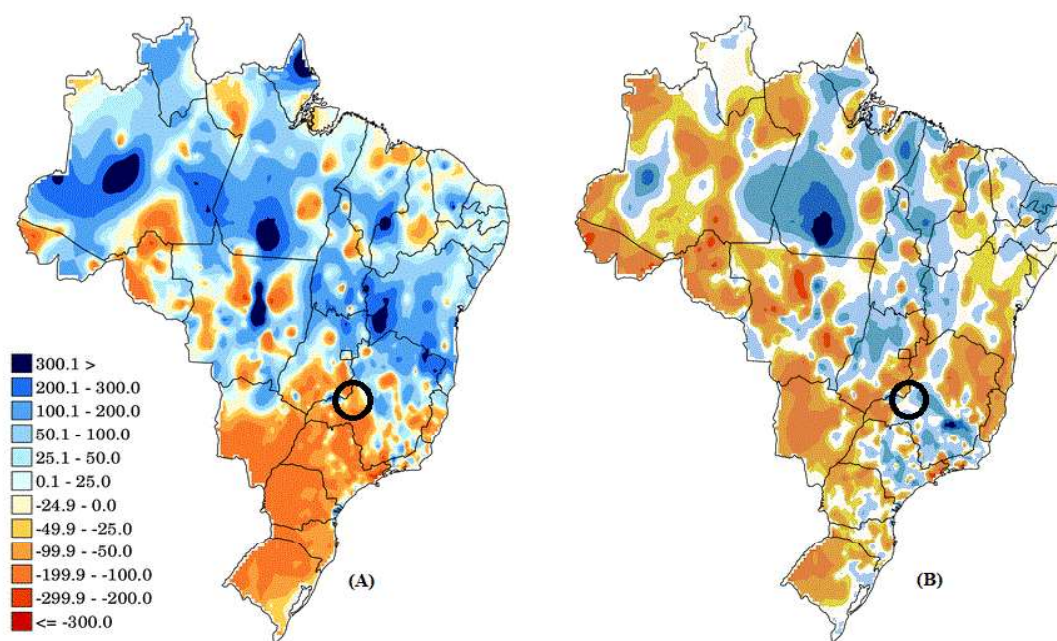


Figura 5. Representação gráfica da anomalia da precipitação média da propriedade nos meses de Dezembro/2021 (A) e Janeiro/2022 (B).



3.2 Características de fibra utilizadas

Após a coleta e processamento das 11.042 amostras de qualidade de fibra de diferentes cultivares de algodão, procedeu-se para a seleção dos dados das seguintes características: uniformidade do comprimento, comprimento de fibra, resistência e índice micronaire.

Uniformidade do comprimento indica a proporção das fibras mais curtas da amostra. É o valor médio de comprimento de fibra baseado na relação percentual entre comprimento médio e o comprimento UHM (*Upper Half Mean*) fornecidos pelo HVI. É classificado como: Muito uniforme - maior que 85%; Uniforme – de 83% á 85%; Média – 80% á 82%; Irregular – 77% á 79%; Muito irregular – menor que 77% (BRASIL, 2002).

Comprimento de fibra ou UHML (mm) é a medida do comprimento médio das fibras de uma amostra dispostas em um pente ou pinça especial. A escala de valores obedece aos padrões de classificações do CNPA (EMBRAPA) em milímetros: Fibra curta: 23,5 à 27,2; Média: 27,3 à 27,9 e Longa: 31,5 à 31,8 (BRASIL, 2002).

Resistência de fibra (gf.tex^{-1}) é determinada pela parede secundária, ou seja, pela quantidade de celulose depositada da fibra, sendo o esforço de tração que se aplica às fibras para provocar à ruptura das mesmas. Obedece-se a seguinte classificação em unidade gf.tex : Muito forte – maior que 34; Forte – 31 a 33; Média – 27 a 30; Fraca – 23 a 26; Muito fraca – abaixo de 22. O ideal para seleção são fibras com valores acima de 28 gf.tex^{-1} (BRASIL, 2002).

Índice de Micronaire é determinado pelo NIR (*Near Infra Red*). O micronaire é obtido pelo método “Air Flow” e baseia-se no princípio do escoamento de um fluido compressível (ar) por um recipiente com uma massa determinada de fibras, que reflete o espessamento da camada celulósica da fibra. O resultado é dado em $\mu\text{g. polegada}^{-1}$. A classificação é: Muito fina – menor que 3,0; Fina – de 3,0 a 3,4; Média – 3,5 a 4,8; Grossa – 4,9 a 5,9 e Muito Grossa – maior que 5,9 (BRASIL, 2002).

3.3 Análises estatísticas

O software SPSS 22 (IBM Corporation) foi utilizado para calcular o coeficiente de Pearson entre uniformidade do comprimento, comprimento de fibra, resistência, índice micronaire e precipitação pluviométrica e temperatura média do ar. Os valores de precipitação pluviométrica de 01/12/2021 a 31/01/2022, temperatura média do ar de 01/12/2021 a 31/01/2022, uniformidade do comprimento, comprimento de fibra,

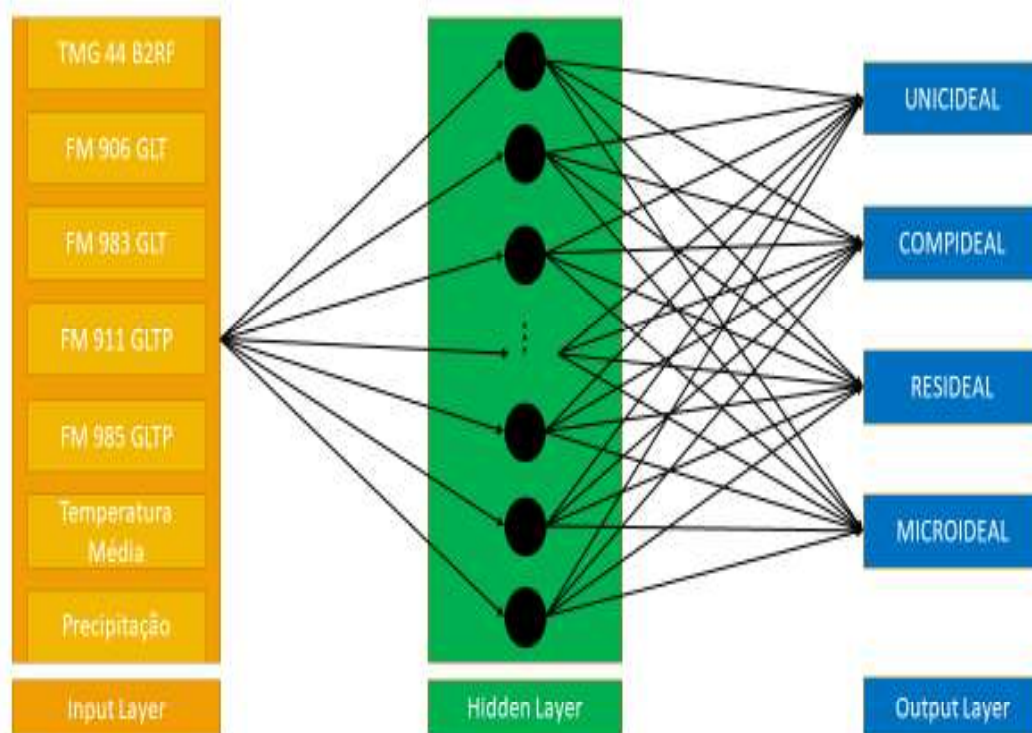
resistência e índice micronaire de cada cultivar foram utilizados como camada de entrada (variáveis independentes), UNICDEAL (uniformidade do comprimento ideal), COMPIDEAL (comprimento de fibra ideal), RESIDEAL (resistência ideal) e MICROIDEAL (índice micronaire ideal) como camada de saída (variáveis dependentes) (Figura 2).

Para fazer um uso mais eficaz da rede neural, as duas camadas de dados foram normalizadas. Neste estudo, usamos 70% dos dados aleatoriamente para treinar o modelo RNA, 15% dos dados foram usados para verificar o modelo de RNA, e os 15% restantes dos dados foram usados para testar o modelo RNA. A seguinte equação foi usada para normalizar os dados (SHABANI et al., 2017):

$$D_n = \frac{D - D_{min}}{D_{max} - D_{min}}$$

Na equação, D é o dado original, D_n são valores de saída normalizados ou valores de entrada, e D_{min} e D_{max} são os valores mínimo e máximo da variável relacionada.

Figura 6. Estrutura de redes neurais artificiais (RNAs) perceptron multicamadas para prever UNICDEAL (uniformidade do comprimento ideal), COMPIDEAL (comprimento de fibra ideal), RESIDEAL (resistência ideal) e MICROIDEAL (índice micronaire ideal) em função da data de plantio.



O software MATLAB (BEALE et al., 2015) foi utilizado para aplicar e testar várias funções de treinamento. As equações para a função de ativação estão descritas abaixo.

- Função Sigmoid tangencial:

$$Fa = \frac{2}{1 + e^{-2a}} - 1$$

- Função Log-sigmoid:

$$Fa = \frac{1}{1 + e^a}$$

Foram testadas quatro diferentes funções de treinamento, duas funções de ativação e camadas ocultas para encontrar o modelo final e avaliar o desempenho dos modelos de RNA determinando o coeficiente (R^2), raiz quadrada do erro médio (RQEM), erro padrão relativo (EPR), erro médio absoluto (EMA) e erro percentual absoluto médio (EPAM). As equações foram os seguintes:

$$R^2 = \frac{\sum_{i=1}^n (Mi - \bar{M})(Pi - \bar{P})}{\sqrt{\sum_{i=1}^n (Mi - \bar{M})^2 \sum_{i=1}^n (Pi - \bar{P})^2}}$$

$$RQEM = \sqrt{\frac{1}{n} \sum_{i=1}^n (Mi - Pi)^2}$$

$$EPR = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Mi - Pi)}}{\bar{M}1}$$

$$EMA = \frac{1}{n} \sum_{i=1}^n |Mi - Pi|$$

$$EPAM = \frac{100}{n} \sum_{i=1}^n \left| \frac{Mi - Pi}{Mi} \right|$$

Nas equações, n é o número de dados, e a barra é a média de uma variável, e Mi e Pi representam o valor medido e o valor previsto, respectivamente.

4. RESULTADOS

4.1 Análise prévia dos fardos processados e sua qualidade de fibra

A análise utilizando *HVI* foi realizada em todos os 11.042 fardos colhidos dos materiais comerciais. De maneira geral, em cada característica analisada foram criadas 5 categorias para classificação em percentual de concentração de fardos. Cada cultivar apresentou uma categoria média de concentração de qualidade de fibra “ideal”, segundo os parâmetros de contrato e indústria. Os dados do cultivar FM 983 GLT são mostrados nas Figuras 7, 8, 9 e 10.

Figura 7. Resultados compilados da característica uniformidade de fibra, do cultivar FM983GLT, safra 2021/22.




Figura 8. Resultados compilados da característica comprimento de fibra, do cultivar FM983GLT, safra 2021/22.




Figura 9. Resultados compilados da característica resistência de fibra, do cultivar FM983GLT, safra 2021/22.






Figura 10. Resultados compilados da característica índice micronaire, do cultivar FM983GLT, safra 2021/22.




Os dados do cultivar FM 906 GLT são mostrados nas Figuras 11,12, 13 e 14. Em contraste com a qualidade de fibra do material FM983 GLT, podemos destacar a maior uniformidade de fibra entre todos os fardos, além do menor comprimento de fibra.

Figura 11. Resultados compilados da característica uniformidade de fibra, do cultivar FM906GLT, safra 2021/22.



	DE 0 A 78	DE 78,1 A 80,5	DE 80,6 A 82,5	DE 82,6 A 85	DE 85,1 A 90	TOTAL
Fardos	17	1.052	1.292	138	3	2.502
Média	77,79	79,81	81,33	83,23	85,33	80,77
Porcentagem	0,68%	42,05%	51,64%	5,52%	0,12%	100,00%

Figura 12. Resultados compilados da característica comprimento de fibra, do cultivar FM906GLT, safra 2021/22.



	DE 0 A 27,38	DE 27,39 A 28,17	DE 28,18 A 28,97	DE 28,98 A 29,76	DE 29,77 A 50	TOTAL
Fardos	21	537	1.092	684	168	2.502
Média	27,23	27,86	28,59	29,32	30,06	28,72
Porcentagem	0,84%	21,46%	43,65%	27,34%	6,71%	100,00%

Além disso, podemos destacar a distribuição ao longo das classes com variações acima de 20% no que se refere ao comprimento de fibra, diferenciando-se dos demais materiais. Isso pode ser explicado por conta do ciclo curto do cultivar, sendo o mais precoce de todos os materiais avaliados.

Figura 13. Resultados compilados da característica resistência de fibra, do cultivar FM906GLT, safra 2021/22.





Figura 14. Resultados compilados da característica índice micronaire, do cultivar FM906GLT, safra 2021/22.



Os dados do cultivar FM 985 GLTP são mostrados nas Figuras 15,16, 17 e 18. Em contraste com a qualidade de fibra dos demais, podemos destacar a maior distribuição do comprimento de fibra do cultivar em valores acima de 28,18 mm, com mais de 97% das amostras processadas.

Figura 15. Resultados compilados da característica uniformidade de fibra, do cultivar FM985GLTP, safra 2021/22.




Figura 16. Resultados compilados da característica comprimento de fibra, do cultivar FM985GLTP, safra 2021/22.






Figura 17. Resultados compilados da característica resistência de fibra, do cultivar FM985GLTP, safra 2021/22.



	DE 0 A 26,9	DE 27 A 28	DE 28,1 A 30	DE 30,1 A 32	DE 32,1 A 50	TOTAL
Fardos	0	341	1.097	125	1	1.564
Média	0,00	27,61	28,97	30,53	32,30	28,80
Porcentagem	0,00%	21,80%	70,14%	7,99%	0,06%	100,00%

Figura 18. Resultados compilados da característica índice micronaire, do cultivar FM985GLTP, safra 2021/22.



	DE 0 A 3,49	DE 3,5 A 3,7	DE 3,71 A 4,4	DE 4,41 A 4,9	DE 4,91 A 8,0	TOTAL
Fardos	50	347	1.167	0	0	1.564
Média	3,44	3,63	3,88	0,00	0,00	3,81
Porcentagem	3,20%	22,19%	74,62%	0,00%	0,00%	100,00%

Os dados do cultivar TMG 44 B2RF são mostrados nas Figuras 19, 20, 21 e 22. Em contraste com a qualidade de fibra dos demais, podemos destacar a segunda maior uniformidade de amostras no índice micronaire, além da menor uniformidade de comprimento, em média.

Figura 19. Resultados compilados da característica uniformidade de fibra, do cultivar TMG 44 B2RF, safra 2021/22.




Figura 20. Resultados compilados da característica comprimento de fibra, do cultivar TMG 44 B2RF, safra 2021/22.




Figura 21. Resultados compilados da característica resistência de fibra, do cultivar TMG 44 B2RF, safra 2021/22.





Figura 22. Resultados compilados da característica índice micronaire, do cultivar TMG 44 B2RF, safra 2021/22.



Os dados do cultivar FM911 GLTP são mostrados nas Figuras 23, 24, 25 e 26. Em contraste com a qualidade de fibra dos demais cultivares, podemos destacar a maior uniformidade de fibra média entre todos os fardos, além da maior resistência e comprimento de fibra, em média.

Figura 23. Resultados compilados da característica uniformidade de fibra, do cultivar FM911 GLTP, safra 2021/22.




Figura 24. Resultados compilados da característica comprimento de fibra, do cultivar FM911 GLTP, safra 2021/22.






Figura 25. Resultados compilados da característica resistência de fibra, do cultivar FM911 GLTP, safra 2021/22.



	DE 0 A 26,9	DE 27 A 28	DE 28,1 A 30	DE 30,1 A 32	DE 32,1 A 50	TOTAL
Fardos	0	7	231	498	640	1.376
Média	0,00	28,00	29,35	31,12	32,96	31,66
Porcentagem	0,00%	0,51%	16,79%	36,19%	46,51%	100,00%

Figura 26. Resultados compilados da característica índice micronaire, do cultivar FM911 GLTP, safra 2021/22.



	DE 0 A 3,49	DE 3,5 A 3,7	DE 3,71 A 4,4	DE 4,41 A 4,9	DE 4,91 A 8,0	TOTAL
Fardos	8	415	912	41	0	1.376
Média	3,44	3,61	3,93	4,49	0,00	3,85
Porcentagem	0,58%	30,16%	66,28%	2,98%	0,00%	100,00%

4.2 Análise do coeficiente de correlação de Pearson

O resultado da análise de correlação simples entre UNIC, COMP, RESI e MICRO para cada cultivar são mostrados nas Tabelas 1 a 6. A temperatura média e a pluviosidade demonstraram correlações extremamente significativamente positivas com todas as predições dos cultivares FM985 GLTP, TMG 44 B2RF, FM911 GLTP e FM983 GLT, exceto MICRO para todos os cultivares.

Tabela 1. Coeficiente de correlação de Pearson de variáveis de entrada UNIC, COMP, RESI e MICRO usadas nos modelos de RNAs, referente ao dia 01/12/2021 à 10/12/2021.

-0,58	0,40	-0,99	0,49	-0,46	0,62	0,08	-0,83	0,00	0,46	1,00	-0,88	-0,69	0,86	-0,56	-0,67	-0,04	-0,79	0,53	0,35	UNIC FM983GLT	1,00
0,49	0,48	0,49	-0,39	-0,75	0,83	0,19	0,43	0,19	0,41	-0,90	0,27	-0,97	0,21	-0,73	-0,39	-0,79	0,77	-0,53	-0,18	UNIC FM906GLT	0,90
-0,53	0,42	-0,02	0,14	-0,29	-0,23	0,55	0,47	0,70	-0,23	0,97	0,95	-0,63	0,31	0,76	-0,21	0,95	0,71	0,60	-0,87	UNIC FM985GLT	0,80
-0,35	-0,23	-0,11	-0,15	-0,45	-0,33	0,11	1,00	0,30	-0,06	-0,04	-0,72	0,72	-0,77	-0,25	0,63	-0,22	-0,78	-0,87	0,14	UNIC TMG44B2RF	0,70
0,86	0,37	0,86	0,82	-0,38	-0,37	0,91	-0,48	-0,01	0,25	-0,69	0,30	0,29	0,19	0,73	-0,36	0,50	0,30	0,70	0,20	UNIC FM911GLT	0,60
0,10	0,15	-0,32	-0,33	0,47	0,88	-0,24	-0,24	0,14	0,26	-0,64	-0,21	-0,10	0,54	0,19	0,98	-0,03	-0,20	0,81	-0,07	COMP FM983GLT	0,50
0,47	-0,97	-0,40	0,09	-0,45	0,58	0,29	-0,92	0,89	0,44	-0,25	0,85	-0,41	-0,37	0,83	0,33	-0,52	0,19	0,18	-0,45	COMP FM906GLT	0,40
0,04	0,79	0,62	0,21	0,23	-0,71	-0,78	0,49	-0,73	-0,12	-0,09	-0,68	0,86	0,70	-0,96	-0,44	0,26	0,51	-0,87	0,75	COMP FM985GLT	0,30
0,47	0,10	-0,55	-0,83	0,67	0,83	-0,14	-0,34	-0,44	-0,30	-0,27	-0,68	0,74	0,74	-0,79	-0,28	-0,20	0,92	-0,41	0,36	COMP TMG44B2RF	0,20
0,82	-0,49	-0,08	0,47	0,40	-0,46	0,45	0,23	-0,09	0,36	-0,10	-0,15	-0,97	0,47	0,40	0,78	-0,11	0,84	-0,46	-0,27	COMP FM911GLT	0,10
-0,60	0,78	-0,90	0,40	-0,96	-0,62	-0,88	0,63	0,36	0,65	0,45	-0,63	0,99	0,18	0,77	0,06	0,52	-0,92	-0,46	-0,28	RESI FM983GLT	0,00
-0,34	0,97	-0,21	0,39	0,02	0,44	-0,31	0,49	-0,83	0,67	0,79	0,88	-0,45	0,42	0,47	-0,34	0,42	-0,22	0,96	-0,86	RESI FM906GLT	-0,10
-0,12	-0,07	0,30	0,69	-0,43	-0,16	0,51	-0,57	0,91	0,13	0,93	0,29	0,02	-0,69	0,01	-0,11	0,42	0,93	-0,98	0,92	RESI FM985GLT	-0,20
0,21	-0,28	-0,81	0,33	0,12	0,30	-0,71	-0,66	0,99	0,88	-0,95	-0,70	-0,80	0,20	-0,50	0,69	0,89	0,95	0,32	-0,70	RESI TMG44B2RF	-0,30
-0,34	0,89	-0,65	-0,78	0,98	0,43	0,96	0,52	0,61	0,16	-0,56	1,00	-0,33	-0,52	0,28	0,22	-0,42	-0,76	0,66	0,04	RESI FM911GLT	-0,40
0,00	-0,06	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,14	0,00	0,00	0,00	0,00	0,00	0,00	-0,12	-0,13	0,00	MICRO FM983GLT	-0,50
0,00	0,00	0,00	-0,13	0,00	0,00	0,00	0,00	-0,05	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	MICRO FM906GLT	-0,60
0,00	0,00	-0,13	0,00	-0,12	0,00	-0,04	0,00	0,00	0,00	0,00	-0,06	0,00	0,00	0,00	0,00	-0,02	0,00	0,00	0,00	MICRO FM985GLT	-0,70
0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,01	0,00	-0,13	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,15	0,00	MICRO TMG44B2RF	-0,80
0,00	0,00	0,00	0,00	0,04	0,00	-0,04	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,07	0,00	MICRO FM911GLT	-0,90
01/12/2021	T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P	10/12/2021

T: Temperatura Média; P: Precipitação pluviométrica; UNIC: Uniformidade do comprimento da fibra; COMP: Comprimento da fibra; RESI: Resistência da fibra; MICRO: índice micronaire.

Tabela 2. Coeficiente de correlação de Pearson de variáveis de entrada UNIC, COMP, RESI e MICRO usadas nos modelos de RNAs, referente ao dia 10/12/2021 à 20/12/2021.

-0,39	-0,73	-0,83	0,17	-0,75	-0,23	-1,00	-0,93	-0,88	-0,90	-0,16	-0,37	-0,67	-0,54	0,59	-0,97	0,81	0,89	0,73	0,66	UNIC FM983GLT	1,00
-0,63	0,61	-0,10	0,96	-0,23	-0,77	0,04	0,75	-0,42	0,95	-0,25	0,80	-0,45	0,46	-0,29	0,48	0,40	0,69	-0,73	0,28	UNIC FM906GLT	0,90
-0,89	-0,70	0,67	-0,57	-0,64	0,38	0,91	-0,79	-0,15	-0,77	-0,79	0,91	-0,25	-0,21	-0,83	0,77	-0,45	-0,50	0,58	-0,13	UNIC FM985GLT	0,80
0,84	0,26	-0,76	-0,13	0,06	-0,01	0,56	-0,39	0,62	0,44	0,88	0,64	-0,32	-0,96	0,73	-0,16	0,06	0,14	-0,34	-0,92	UNIC TMG44B2RF	0,70
0,54	-0,39	0,59	-0,26	0,39	0,08	-0,42	0,96	-0,96	-0,54	-0,91	0,99	0,94	0,27	-0,89	0,01	0,71	0,01	-0,03	-0,22	UNIC FM911GLT	0,60
0,87	0,75	0,58	-0,30	0,32	0,10	0,79	-0,35	0,64	0,43	0,07	0,12	-0,35	-0,63	0,92	-0,92	0,09	-0,25	0,20	-0,37	COMP FM983GLT	0,50
-0,07	0,57	-0,57	-0,70	0,41	0,91	-0,01	-0,63	0,95	-0,30	0,98	-0,17	0,14	0,94	-0,91	-0,32	-0,03	0,76	0,27	0,17	COMP FM906GLT	0,40
-0,61	0,00	-0,49	0,19	0,76	-0,37	-0,28	-0,72	-0,13	0,67	-0,86	-0,67	-0,84	-0,34	-0,24	0,82	0,94	-0,83	0,04	0,93	COMP FM985GLT	0,30
0,35	-0,92	0,78	-0,95	0,89	-0,08	-0,59	0,13	0,35	-0,93	-0,17	0,22	0,39	0,80	-0,75	0,83	0,06	-0,09	-0,34	0,20	COMP TMG44B2RF	0,20
0,52	-0,40	-0,40	0,01	0,82	-0,45	0,99	0,07	0,49	-0,25	-0,52	0,09	0,87	-0,99	0,88	-0,23	-0,37	-0,11	0,50	-0,22	COMP FM911GLT	0,10
0,71	-0,40	0,35	0,95	-0,17	0,47	0,47	0,40	-0,82	0,54	0,85	0,08	0,81	-0,38	-0,87	0,45	-0,75	0,92	0,23	0,38	RESI FM983GLT	0,00
0,27	-0,10	0,08	-0,40	0,14	0,48	-0,08	-0,50	0,30	-0,22	-0,11	0,40	0,74	0,45	0,11	-0,61	0,13	-0,90	-0,08	0,16	RESI FM906GLT	-0,10
-0,12	-0,79	0,48	0,80	0,68	-0,76	-0,42	-0,13	-0,41	0,49	-0,31	-0,05	-0,01	-0,95	-0,24	0,17	-0,95	-0,31	0,78	0,80	RESI FM985GLT	-0,20
-0,06	0,71	-0,13	0,45	-0,96	0,28	-0,28	0,88	-0,13	0,49	0,52	0,43	-0,35	-0,68	0,92	-0,69	-0,03	0,98	0,74	-0,86	RESI TMG44B2RF	-0,30
0,98	-0,37	-0,16	-0,21	-0,14	0,80	-0,28	0,62	-0,01	0,90	-0,13	0,26	0,38	0,82	0,49	0,51	0,56	0,12	0,31	-0,51	RESI FM911GLT	-0,40
0,69	-0,63	0,99	-0,83	-0,19	-0,47	0,18	-0,69	0,22	0,69	-0,29	-0,59	-0,99	-0,30	0,37	-0,45	0,17	-0,13	0,24	-0,65	MICRO FM983GLT	-0,50
-0,03	-0,12	0,00	0,00	0,00	0,00	0,00	0,00	-0,03	0,00	0,00	0,00	-0,07	-0,08	0,00	0,00	0,14	0,00	0,00	0,00	MICRO FM906GLT	-0,60
0,00	0,00	0,00	0,00	0,00	0,00	0,18	0,00	-0,08	0,04	0,00	0,00	0,17	0,00	0,00	0,00	0,00	0,00	0,00	0,00	MICRO FM985GLT	-0,70
0,00	0,11	-0,16	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,12	0,00	MICRO TMG44B2RF	-0,80
0,00	0,00	-0,02	0,08	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,12	0,00	0,00	0,00	0,00	0,02	MICRO FM911GLT	-0,90
11/12/2021	12/12/2021	13/12/2021	14/12/2021	15/12/2021	16/12/2021	17/12/2021	18/12/2021	19/12/2021	20/12/2021												-1,00
T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	

T: Temperatura Média; P: Precipitação pluviométrica; UNIC: Uniformidade do comprimento da fibra; COMP: Comprimento da fibra; RESI: Resistência da fibra; MICRO: índice micronaire.

Tabela 3. Coeficiente de correlação de Pearson de variáveis de entrada UNIC, COMP, RESI e MICRO usadas nos modelos de RNAs, referente ao dia 21/12/2021 à 30/12/2021.

0,60	0,09	0,10	-0,21	0,22	0,53	-0,54	0,63	0,49	0,69	-0,20	0,75	-0,53	-0,72	-0,91	0,17	0,73	0,99	0,73	-0,49	UNIC FM983GLT	1,00
0,25	0,06	-0,43	-0,34	0,64	-0,22	0,29	0,10	0,62	-0,21	-0,75	0,07	0,51	0,74	-0,49	-0,57	-0,77	-0,89	0,83	0,36	UNIC FM906GLT	0,90
0,20	-0,37	0,57	0,20	0,24	0,62	-0,70	-0,70	-0,85	0,17	-0,81	-0,12	0,14	0,01	0,67	-0,40	-0,45	0,31	-0,22	-0,95	UNIC FM985GLT	0,80
-0,26	-0,40	0,40	-0,73	0,69	0,06	-0,02	0,45	0,15	0,51	-0,14	0,54	0,04	0,71	-0,47	-0,43	-0,88	0,63	-0,97	0,12	UNIC TMG44B2RF	0,70
0,65	-0,03	0,50	-0,92	0,44	0,90	-0,50	-0,44	-0,47	0,19	-0,37	0,65	0,20	-0,75	-0,89	0,49	-0,41	0,17	-0,59	-0,02	UNIC FM911GLT	0,60
-0,56	0,31	0,64	0,53	-0,10	0,55	0,86	0,43	0,89	0,01	-0,17	0,08	-0,54	-0,49	0,95	0,10	-0,85	0,03	-0,99	-0,28	COMP FM983GLT	0,50
-0,61	-0,18	-0,93	-0,80	0,46	-0,53	0,76	0,65	0,65	-0,24	0,78	-0,46	0,16	-0,87	-0,12	-0,46	0,89	0,13	-0,08	-0,14	COMP FM906GLT	0,40
0,32	-0,23	0,17	-0,80	-0,96	0,30	0,70	-0,47	0,63	0,19	-0,19	0,12	0,81	-0,64	-0,93	-0,46	0,43	0,78	0,16	-0,40	COMP FM985GLT	0,30
0,78	0,00	0,69	-0,53	-0,51	0,31	-0,94	0,58	-0,26	0,24	-0,65	0,90	0,82	-0,39	0,87	-0,60	-1,00	0,60	0,93	0,70	COMP TMG44B2RF	0,20
-0,39	-0,69	0,36	0,94	-0,31	-0,84	0,06	0,65	0,25	-0,32	0,62	-0,97	-0,38	-0,83	-0,31	0,52	0,55	0,14	0,53	-0,08	COMP FM911GLT	0,10
0,89	-0,24	-0,58	-0,95	0,61	0,14	-0,13	-0,17	0,75	-0,58	-0,02	0,32	0,86	-0,05	0,02	-0,07	-0,94	-0,91	0,60	-0,12	RESI FM983GLT	0,00
0,50	0,26	0,67	0,56	-0,56	-0,02	0,30	0,34	-0,48	0,04	0,03	-0,17	0,25	-0,42	0,26	0,74	0,00	-0,94	-0,27	0,64	RESI FM906GLT	-0,10
-0,86	0,96	0,96	0,75	-0,86	-0,42	-0,24	-0,78	0,44	0,42	-0,71	0,29	0,79	-0,84	-0,45	-0,04	0,43	-0,53	0,42	-0,44	RESI FM985GLT	-0,20
0,56	0,97	0,65	-0,01	-0,66	-0,69	-0,54	-0,50	-0,16	0,92	0,82	-0,31	0,93	-0,81	0,59	0,31	-0,60	-0,95	-0,67	-0,09	RESI TMG44B2RF	-0,30
-0,93	0,08	0,24	-0,64	-0,46	0,68	-0,46	-0,96	-0,75	0,96	0,80	0,47	0,55	-0,70	-0,97	-0,51	-0,60	0,34	-0,77	-0,77	RESI FM911GLT	-0,40
0,00	0,00	-0,17	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,06	0,00	0,00	0,02	0,00	0,00	0,00	MICRO FM983GLT	-0,50
0,00	0,00	0,00	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,09	0,00	0,00	0,00	0,00	0,00	MICRO FM906GLT	-0,60
0,00	0,00	0,00	0,00	-0,11	0,26	0,00	0,00	0,00	0,14	0,00	0,00	0,00	-0,10	0,05	0,00	0,00	-0,12	-0,11	0,00	MICRO FM985GLT	-0,70
0,00	0,00	0,17	-0,07	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,19	0,00	0,00	0,03	0,00	0,00	0,00	0,00	MICRO TMG44B2RF	-0,80
0,00	0,01	0,00	0,00	-0,04	0,00	0,00	0,00	0,00	0,00	0,20	0,00	0,00	-0,07	0,00	0,00	0,01	0,00	0,00	0,00	MICRO FM911GLT	-0,90
-1,00																					-1,00

21/12/2021	22/12/2021	23/12/2021	24/12/2021	25/12/2021	26/12/2021	27/12/2021	28/12/2021	29/12/2021	30/12/2021
T	P	T	P	T	P	T	P	T	P

T: Temperatura Média; P: Precipitação pluviométrica; UNIC: Uniformidade do comprimento da fibra; COMP: Comprimento da fibra; RESI: Resistência da fibra; MICRO: índice micronaire.

Tabela 4. Coeficiente de correlação de Pearson de variáveis de entrada UNIC, COMP, RESI e MICRO usadas nos modelos de RNAs, referente ao dia 31/12/2021 à 09/01/2022.

0,43	0,14	-0,89	-0,46	-0,44	0,12	-0,10	-0,37	0,51	0,68	-0,77	-0,25	-0,28	0,95	-0,63	0,13	UNIC FM983GLT	1,00
0,46	-0,68	0,77	0,28	0,29	-0,24	-0,30	0,56	0,78	0,28	-0,43	0,71	0,35	-0,68	0,12	-0,58	UNIC FM906GLT	0,90
0,05	-0,83	-0,03	-0,84	-0,87	0,87	0,44	-0,42	-0,53	0,10	-0,78	0,68	0,36	-0,23	0,28	0,49	UNIC FM985GLT	0,80
-0,33	-0,52	0,36	-0,53	-0,42	0,09	-0,49	-0,04	0,68	-0,95	-0,38	-0,15	-0,19	-0,89	0,16	0,44	UNIC TMG44B2RF	0,70
0,97	0,65	-0,43	0,03	-0,05	0,97	0,49	-0,96	0,39	0,94	-0,48	-0,40	0,03	-0,84	-0,45	0,37	UNIC FM911GLT	0,60
-0,06	0,66	0,31	-0,03	0,10	-0,84	-0,91	-0,30	0,21	0,93	-0,18	0,92	-0,81	-0,62	-0,38	-0,99	COMP FM983GLT	0,50
-0,95	-0,91	-0,55	0,83	0,32	-0,41	0,90	0,04	-0,57	0,25	0,89	-0,17	0,42	0,22	-0,12	0,52	COMP FM906GLT	0,40
0,22	0,35	0,22	-0,34	0,19	-0,03	-0,40	0,70	0,00	-0,91	-0,89	-0,44	0,57	0,12	0,93	-0,77	COMP FM985GLT	0,30
0,57	0,54	0,14	0,96	0,23	-0,72	-0,12	-0,48	-0,76	0,34	0,50	0,45	-0,56	0,48	-0,80	-0,19	COMP TMG44B2RF	0,20
-0,30	-0,04	-0,68	-0,48	-0,65	-0,04	-0,49	-0,73	-0,47	0,82	0,62	0,89	-0,52	0,98	-0,65	-0,19	COMP FM911GLT	0,10
-0,35	-0,90	0,10	-0,90	0,18	0,11	0,14	0,47	0,11	-0,06	-0,93	0,82	0,46	-0,04	0,27	0,84	RESI FM983GLT	0,00
-0,12	0,04	-0,58	-0,65	0,92	0,85	-0,27	0,69	-0,96	0,32	0,65	-0,61	-0,09	0,16	0,01	-0,09	RESI FM906GLT	-0,10
-0,68	0,86	0,96	-0,60	0,03	-0,86	-0,42	0,43	0,60	-0,84	0,96	0,35	0,41	-0,34	0,18	-0,41	RESI FM985GLT	-0,20
0,99	0,57	0,93	0,73	-0,04	0,94	0,06	0,04	-0,72	0,30	0,96	-0,55	0,05	0,58	0,16	-0,50	RESI TMG44B2RF	-0,30
-0,52	-0,13	-0,26	-0,72	-0,33	-0,28	-0,12	0,35	0,35	0,07	-0,28	0,24	0,27	0,85	0,16	-0,25	RESI FM911GLT	-0,40
0,16	-0,31	-0,15	0,59	0,50	0,88	0,04	0,61	0,61	0,06	-0,76	-0,89	0,17	0,62	-0,63	0,84	MICRO FM983GLT	-0,50
-0,02	0,00	-0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,10	0,00	0,00	0,00	MICRO FM906GLT	-0,60
0,00	0,00	0,00	-0,24	0,00	0,12	0,00	0,12	0,00	0,00	0,00	0,00	0,00	-0,18	0,00	0,00	MICRO FM985GLT	-0,70
-0,19	0,00	0,00	0,00	-0,09	0,00	0,00	0,00	-0,10	0,00	0,14	0,00	-0,15	0,00	0,04	-0,02	MICRO TMG44B2RF	-0,80
0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,14	0,00	0,00	0,00	0,00	0,00	0,00	0,00	MICRO FM911GLT	-0,90
31/12/2021	01/01/2022	02/01/2022	03/01/2022	04/01/2022	05/01/2022	06/01/2022	07/01/2022	08/01/2022	09/01/2022								-1,00
T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P		

T: Temperatura Média; P: Precipitação pluviométrica; UNIC: Uniformidade do comprimento da fibra; COMP: Comprimento da fibra; RESI: Resistência da fibra; MICRO: índice micronaire.

Tabela 5. Coeficiente de correlação de Pearson de variáveis de entrada UNIC, COMP, RESI e MICRO usadas nos modelos de RNAs, referente ao dia 10/01/2022 à 19/01/2022.

-0,34	0,79	-0,78	0,85	-0,31	-0,76	-0,05	0,33	0,12	-0,13	-0,91	0,26	-0,45	-0,78	0,76	-0,95	-0,81	0,19	0,29	0,31	UNIC FM983GLT	1,00
0,25	0,26	-0,64	-0,91	-0,65	-0,76	-0,41	-0,52	-0,95	0,81	-0,75	0,13	0,02	0,59	-0,16	0,65	0,89	0,85	0,67	-0,59	UNIC FM906GLT	0,90
0,45	0,66	-0,34	-0,84	0,51	0,56	-0,29	-0,11	-0,64	0,03	-0,10	-0,23	0,67	0,94	-0,01	0,31	-0,15	0,59	0,69	0,60	UNIC FM985GLTP	0,80
0,34	0,01	0,14	0,73	-0,69	-0,80	0,79	0,95	0,20	-0,97	0,61	0,87	-0,29	-0,17	0,48	0,38	-0,22	-0,03	0,07	0,35	UNIC TMG44B2RF	0,70
-0,03	0,09	0,78	-0,01	0,83	-0,64	-0,12	-0,73	0,53	-0,18	0,34	-0,25	0,32	-0,88	0,97	-0,69	0,86	0,62	-0,71	-0,19	UNIC FM911GLTP	0,60
-0,72	-0,64	0,05	0,39	0,78	-0,64	0,76	0,29	0,05	0,47	0,19	-0,40	0,48	0,25	-0,35	-0,34	-0,34	0,74	-0,75	-0,70	COMP FM983GLT	0,50
0,93	-0,86	-0,30	-0,82	-0,54	0,72	-0,25	-0,31	0,77	-0,80	-0,85	-0,61	0,32	-0,70	-0,85	-0,81	0,52	0,18	-0,23	0,81	COMP FM906GLT	0,40
-0,87	0,62	-0,09	0,11	-0,17	-0,49	-0,78	-0,87	0,72	-0,87	0,21	-0,65	0,92	-0,05	-0,18	-0,71	-0,19	-0,94	0,80	-0,46	COMP FM985GLTP	0,30
-0,73	0,02	-0,71	0,30	0,59	0,05	0,21	-0,11	-0,76	0,31	-0,40	0,14	-0,04	-0,46	-0,86	-0,05	-0,94	-0,92	0,35	-0,36	COMP TMG44B2RF	0,20
-0,67	0,85	-0,75	-0,17	-0,39	0,96	-0,27	-0,87	-0,09	-0,99	-0,39	0,01	-0,38	-0,64	-1,00	-0,87	0,21	-0,77	-0,49	-0,05	COMP FM911GLTP	0,10
0,78	0,47	-0,89	-0,36	-0,30	-0,06	0,93	0,51	0,39	0,01	-0,60	0,11	-0,32	-0,04	-0,24	0,05	-0,10	-0,85	0,38	0,00	RESI FM983GLT	0,00
-0,93	0,81	0,23	0,16	0,81	0,98	0,10	0,95	-0,34	0,24	-0,96	0,33	-0,02	-0,13	-0,58	0,34	0,52	-0,88	-0,62	0,89	RESI FM906GLT	-0,10
0,08	0,06	0,19	0,56	0,84	0,18	0,79	0,23	0,22	-0,90	0,08	0,93	0,78	-0,57	-0,06	-0,27	-0,09	0,99	0,86	0,00	RESI FM985GLTP	-0,20
0,21	-0,85	0,70	-0,06	0,34	-0,47	-0,85	0,16	-0,27	0,14	-0,29	0,87	-0,07	-0,87	0,06	-0,23	-0,56	-0,45	-0,79	0,12	RESI TMG44B2RF	-0,30
-0,46	-0,65	0,60	-0,12	-0,01	0,92	0,77	-0,73	-0,10	0,81	0,63	-0,21	-0,33	-0,63	0,68	-0,10	-0,61	-0,80	0,81	0,99	RESI FM911GLTP	-0,40
0,00	0,00	0,00	0,00	0,00	-0,14	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,20	0,00	0,00	0,00	0,00	0,00	-0,02	MICRO FM983GLT	-0,50
0,00	0,00	0,00	0,00	-0,09	0,09	0,00	0,00	0,06	-0,05	0,00	0,00	-0,09	0,00	0,14	0,00	0,00	0,00	0,00	0,10	MICRO FM906GLT	-0,60
0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	-0,08	0,00	0,00	0,00	0,00	MICRO FM985GLTP	-0,70
0,02	0,07	-0,09	0,00	0,06	0,00	0,00	0,00	0,00	0,00	0,00	0,08	0,00	0,18	0,00	0,00	0,00	0,00	0,00	0,00	MICRO TMG44B2RF	-0,80
0,00	0,03	0,00	0,08	0,00	0,00	0,00	0,00	-0,05	0,10	-0,14	0,00	0,05	-0,09	0,00	0,00	0,00	0,00	0,00	0,00	MICRO FM911GLTP	-0,90
10/01/2022	11/01/2022	12/01/2022	13/01/2022	14/01/2022	15/01/2022	16/01/2022	17/01/2022	18/01/2022	19/01/2022	19/01/2022	19/01/2022	19/01/2022	19/01/2022	19/01/2022	19/01/2022	19/01/2022	19/01/2022	19/01/2022	19/01/2022	19/01/2022	-1,00
T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P	T	P	P	

T: Temperatura Média; P: Precipitação pluviométrica; UNIC: Uniformidade do comprimento da fibra; COMP: Comprimento da fibra; RESI: Resistência da fibra; MICRO: índice micronaire.

Tabela 6. Coeficiente de correlação de Pearson de variáveis de entrada UNIC, COMP, RESI e MICRO usadas nos modelos de RNAs, referente ao dia 20/01/2022 à 31/01/2022.

0,03	0,52	-0,59	0,53	-0,61	0,11	-0,86	-0,63	-0,13	-0,71	-0,85	0,85	-0,57	0,71	0,70	0,85	0,44	-0,43	-0,19	0,39	0,17	-0,15	0,02	0,15	UNIC FM983GLT
0,48	-0,28	0,29	0,37	-0,82	0,34	0,90	0,32	0,07	-0,26	-0,73	-0,79	-0,59	-0,39	0,66	0,58	0,56	0,32	0,42	-0,31	0,09	-0,77	-0,28	0,92	UNIC FM906GLT
0,51	0,17	0,14	0,40	0,87	0,31	0,42	-0,29	0,63	0,12	0,02	-0,64	0,35	0,72	0,34	-0,95	-0,45	0,71	-0,56	-0,79	-0,91	0,48	-0,82	0,79	UNIC FM985GLTP
-0,84	0,23	-0,97	0,16	-0,30	0,71	0,54	0,21	0,06	0,55	0,07	-0,48	0,03	0,23	-0,69	-0,54	-0,40	0,48	-0,50	-0,53	-0,79	0,84	-0,56	0,74	UNIC TMG44B2RF
0,20	-0,62	0,63	-0,26	0,50	-0,97	0,11	-0,43	-0,40	-0,26	-0,34	-0,11	-0,29	-0,54	-0,97	0,55	0,04	0,53	0,45	0,09	-0,01	-0,99	0,93	-0,93	UNIC FM911GLTP
-0,12	0,04	-0,84	0,97	0,36	-0,09	0,76	-0,74	-0,65	0,68	-0,63	-0,17	-0,28	0,88	0,68	0,22	-0,76	-0,69	0,71	0,31	-0,14	-0,57	-0,64	-0,05	COMP FM983GLT
0,35	0,86	-0,90	-0,14	0,50	-0,96	0,60	0,08	-0,22	0,05	0,86	-0,76	-0,30	-0,63	0,64	-0,52	-0,15	0,20	-0,45	-0,14	-0,57	-0,02	0,89	-0,80	COMP FM906GLT
-0,34	-0,53	0,68	-0,08	-0,55	0,54	0,30	0,39	-0,05	0,56	-0,55	0,10	0,50	-0,64	0,25	-0,81	0,81	0,27	0,01	0,79	-0,42	-0,11	-0,73	0,29	COMP FM985GLTP
0,80	-0,27	-0,75	-0,55	0,82	0,73	0,53	-0,10	0,75	-0,86	-0,61	0,67	-0,74	0,14	0,67	-0,94	-0,74	0,02	0,28	-0,10	0,99	0,58	-0,48	-0,46	COMP TMG44B2RF
-0,71	-0,56	-0,09	-0,22	-0,97	0,48	0,55	0,21	-0,54	-0,24	0,75	0,60	-0,77	-0,70	0,86	-0,84	0,91	-0,13	0,79	0,97	0,29	0,93	0,41	-0,32	COMP FM911GLTP
0,09	0,30	-0,43	-0,93	0,31	0,86	-0,34	0,74	0,73	0,51	-0,11	0,06	0,56	0,62	-0,35	0,01	0,03	0,59	0,54	-0,66	-0,98	-0,74	0,97	0,90	RESI FM983GLT
0,42	-0,34	0,91	0,42	0,48	-0,12	-0,20	-0,40	-0,97	-0,77	0,61	0,59	0,30	-0,80	0,86	-0,99	-0,08	0,90	0,07	-0,19	-0,75	-1,00	-0,63	-0,14	RESI FM906GLT
-0,64	0,06	-0,80	0,99	0,48	0,71	-0,40	0,81	0,58	0,55	-0,09	-0,30	0,79	-1,00	-0,67	-0,88	0,69	-0,48	-0,96	0,06	0,40	0,92	0,92	-0,70	RESI FM985GLTP
0,84	-0,36	-0,14	-0,69	-0,96	-0,55	0,85	-0,21	0,95	-0,11	-0,52	-0,63	-0,18	0,16	0,19	0,45	0,17	0,68	0,46	0,65	-0,27	0,55	0,51	0,83	RESI TMG44B2RF
0,91	-0,15	0,51	-0,34	-0,22	-0,75	0,08	0,98	-0,49	0,43	-0,65	0,38	-0,05	-0,27	0,29	0,40	0,69	0,91	0,86	-0,13	-0,10	-0,60	-0,88	0,64	RESI FM911GLTP
0,00	0,00	0,00	0,00	0,00	0,00	-0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,02	MICRO FM983GLT
0,00	0,00	0,00	0,00	0,00	0,02	0,00	0,00	-0,12	0,00	0,00	0,00	0,10	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,08	-0,01	MICRO FM906GLT
0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,02	-0,09	0,00	-0,19	0,00	0,00	0,00	0,10	0,20	0,00	0,00	MICRO FM985GLTP
0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	MICRO TMG44B2RF
0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	-0,20	-0,02	0,00	0,00	0,00	0,00	0,00	MICRO FM911GLTP

20/01/2022 21/01/2022 22/01/2022 23/01/2022 24/01/2022 25/01/2022 26/01/2022 27/01/2022 28/01/2022 29/01/2022 30/01/2022 31/01/2022

T P T P T P T P T P T P T P T P T P

T: Temperatura Média; P: Precipitação pluviométrica; UNIC: Uniformidade do comprimento da fibra; COMP: Comprimento da fibra; RESI: Resistência da fibra; MICRO: índice micronaire.

Em contraste, a pluviosidade nos dias 27/12/202, 16/01/2022 e 27/01/2022 apresentaram resultados extremamente negativas correlações com UNICIDEAL, COMPIDEAL e RESIDEAL para quase todos os cultivares. Em relação a MICROIDEAL em todos os cultivares a correlação foi nula ou fraca, independentemente de ser positiva ou negativa. A seleção de variáveis de entrada é uma parte crítica da RNA. Neste estudo, selecionamos as variáveis de entrada de acordo com suas altas correlações simples positivas (acima de 0,6) com UNIC, COMP e RESI e simulamos os modelos de RNA com quatro funções de treinamento e duas funções de transferência.

Os resultados de RQEM, EMA, EPR, EPAM e R^2 para cada modelo RNA são mostrados na Tabela 7, 8 e 9.

Tabela 7. Algumas propriedades estatísticas dos resultados de redes neurais artificiais (RNAs) com diferentes funções de treinamento e transferência para a previsão de UNICIDEAL.

Função de Treinamento	Função de Transferência	Melhor Modelo	R^2	RQEM	EPR	EMA	EPAM
BFG	Log-sigmoide	12 - 12 - 1	0,80	0,1820	0,0222	0,1502	0,5109
	Sigmoide tangencial	12 - 11 - 1	0,77	0,1927	0,0271	0,1588	0,5228
CBG	Log-sigmoide	12 - 12 - 1	0,81	0,1922	0,0240	0,1552	0,3772
	Sigmoide tangencial	12 - 12 - 1	0,82	0,1381	0,0283	0,1255	0,3283
CGP	Log-sigmoide	12 - 13 - 1	0,74	0,1782	0,0218	0,1172	0,5722
	Sigmoide tangencial	12 - 11 - 1	0,80	0,1731	0,0211	0,1121	0,5011
LM	Log-sigmoide	12 - 12 - 1	0,90	0,1229	0,0151	0,0895	0,2552
	Sigmoide tangencial	12 - 11 - 1	0,87	0,1527	0,0223	0,1211	0,2533

BFG: BFGS Quasi-Newton back-propagation; CGB: Conjugate Gradient with Powell/Beale Restarts back-propagation; CGP: Polak–Ribière Conjugate Gradient back-propagation; LM: Levenberg–Marquardt back-propagation.

Tabela 8. Algumas propriedades estatísticas dos resultados de redes neurais artificiais (RNAs) com diferentes funções de treinamento e transferência para a previsão de COMPIDEAL.

Função de Treinamento	Função de Transferência	Melhor Modelo	R^2	RQEM	EPR	EMA	EPAM
BFG	Log-sigmoide	10 - 8 - 1	0,77	0,3272	0,0238	0,3220	0,3337
	Sigmoide tangencial	10 - 7 - 1	0,75	0,3632	0,0267	0,3309	0,3930
CBG	Log-sigmoide	10 - 10 - 1	0,83	0,3203	0,0226	0,3328	0,3238
	Sigmoide tangencial	10 - 10 - 1	0,79	0,3382	0,0240	0,3363	0,3336
CGP	Log-sigmoide	10 - 10 - 1	0,86	0,3283	0,0221	0,3222	0,3368
	Sigmoide tangencial	10 - 11 - 1	0,80	0,3270	0,0236	0,3286	0,3780
LM	Log-sigmoide	10 - 11 - 1	0,91	0,0834	0,0063	0,0283	0,2308
	Sigmoide tangencial	10 - 9 - 1	0,84	0,3009	0,0304	0,0763	0,2633

BFG: BFGS Quasi-Newton back-propagation; CGB: Conjugate Gradient with Powell/Beale Restarts back-propagation; CGP: Polak–Ribière Conjugate Gradient back-propagation; LM: Levenberg–Marquardt back-propagation.

Tabela 9. Algumas propriedades estatísticas dos resultados de redes neurais artificiais (RNAs) com diferentes funções de treinamento e transferência para a previsão de RESIDEAL.

Função de Treinamento	Função de Transferência	Melhor Modelo	R ²	RQEM	EPR	EMA	EPAM
BFG	Log-sigmoide	9 - 8 - 1	0,74	0,2617	0,0268	0,2147	0,4981
	Sigmoide tangencial	9 - 10 - 1	0,75	0,2606	0,0278	0,2266	0,4692
CBG	Log-sigmoide	9 - 8 - 1	0,82	0,2164	0,0286	0,2022	0,4027
	Sigmoide tangencial	9 - 12 - 1	0,79	0,2728	0,0211	0,2242	0,4117
CGP	Log-sigmoide	9 - 8 - 1	0,69	0,2787	0,0272	0,2214	0,4729
	Sigmoide tangencial	9 - 10 - 1	0,74	0,2498	0,0224	0,2212	0,1797
LM	Log-sigmoide	9 - 10 - 1	0,95	0,0717	0,0074	0,0516	0,2476
	Sigmoide tangencial	9 - 12 - 1	0,89	0,2069	0,0224	0,0728	0,2427

BFG: BFGS Quasi-Newton back-propagation; CBG: Conjugate Gradient with Powell/Beale Restarts back-propagation; CGP: Polak–Ribière Conjugate Gradient back-propagation; LM: Levenberg–Marquardt back-propagation.

4.3 Predição de UNICIDEAL usando modelo RNAs

Quando a função de treinamento LM foi usada, RNAs com a função de transferência de Log-sigmoide tiveram maior precisão na previsão de UNICIDEAL com R² (0,90) do que RNAs com a função de transferência de sigmoide tangencial. Enquanto nas funções de treinamento CGB e CGP quando utilizadas, RNAs com a transferência função da sigmoide tangencial têm maior precisão na previsão UNICIDEAL com R² (0,82 e 0,80) do que RNAs com a função de transferência de log-sigmoide (Tabela 7). Entre todos os modelos de RNA, o modelo RNA com função de treinamento LM e a função de transferência de log-sigmoide tem o melhor desempenho, pois este modelo de RNA tem o menor EMA (0,08953), EPR (0,01511), EPAM (0,2552) e RQEM (0,1229) e o valor R² mais alto (0,90), e a estrutura da rede neural 12–12– 1 (Tabela 7). Os resultados indicam que este modelo de RNA é confiável e eficaz na previsão da Uniformidade de Comprimento Ideal de todas as cultivares.

4.4 Predição de COMPIDEAL usando modelo RNAs

Os resultados mostram que as RNAs com a função de transferência de log-sigmoide têm maior precisão na previsão do COMPIDEAL com R² (0,77, 0,81, 0,86 e 0,91, respectivamente) do que RNAs com a função de transferência de sigmoide tangencial quando todas as funções de treinamento são comparadas (Tabela 8). Entre todos os modelos de RNA, o modelo RNA com função de treinamento LM e a função de transferência de log-sigmoide tem o melhor desempenho, pois este modelo de RNA tem

o menor EMA (0,02826), EPR (0,006287), EPAM (0,2308), e RQEM (0,08336) e o maior valor de R^2 (0,91), e o valor da estrutura da rede neural é 10–11– 1 (Tabela 8). Os resultados indicam que este modelo de RNA é confiável e eficaz na previsão da Comprimento de Fibra Ideal de todas as cultivares.

4.5 Predição de RESIDEAL usando modelo RNAs

Os resultados mostram RNAs com a função de transferência de log-sigmoide têm maior precisão na previsão da RESIDEAL com R^2 (0,82 e 0,95) do que RNAs com a função de transferência de sigmoide tangencial quando as funções de treinamento CGB e LM são usadas. Enquanto as funções de treinamento BFG e CGP são usadas, RNAs com a função de transferência de sigmoide tangencial tem maior precisão na previsão na resistência de fibra ideal com R^2 (0,75 e 0,74) do que RNAs com a função de transferência de log-sigmoide (Tabela 9).

Entre todas as RNAs modelos, o modelo RNA com função de treinamento LM e a transferência função de log-sigmoide tem o melhor desempenho, porque este modelo RNA tem o EMA mais baixo (0,05162), EPR (0,007424), EPAM (0,2476) e RQEM (0,07167) e o valor R^2 mais alto (0,95), e a estrutura da rede neural é 9–10– 1 (Tabela 9). Os resultados indicam que este modelo de RNA é confiável e eficaz na previsão da Resistência de Fibra Ideal de todas as cultivares.

5. DISCUSSÃO

Os resultados deste estudo mostraram que havia correlações complexas entre cultivares, temperatura e pluviosidade (a variável na entrada camada) e UNICIDEAL, COMPIDEAL e RESIDEAL (a variável na camada de saída). Portanto, é muito importante estabelecer um modelo para prever as principais características intrínsecas da fibra e revelar a sua relação interna para melhorar a qualidade de fibra. No entanto, os métodos matemáticos tradicionais e a modelagem técnicas não podem quantificar com precisão as complexas relações internas mencionadas acima.

Nos últimos anos, o A RNA foi testada na previsão da precisão da qualidade da fibra dentro da indústria (CHIA et al., 2012) e diâmetro do fio de algodão cardado (LAN et al., 2020; KHADDAM; AHMAD, 2022). Os resultados indicam que o modelo RNA é uma ferramenta muito útil e confiável, além de ser uma poderosa ferramenta preditiva, e sua alta precisão de previsão é muito satisfatória. Para explorar o modelo de previsão

mais eficaz, comparamos os modelos RNAs resultados de diferentes funções de treinamento e funções de transferência. Os resultados mostram que o modelo RNA com função de treinamento LM e função de transferência log-sigmoide apresentam a maior precisão, porque seus valores de RQEM, EMA e RSE são os valores mais baixos e R^2 são os mais altos. Isto está relacionado principalmente com a natureza dos itens acima.

A função de transferência log-sigmoide não tem restrições das variáveis de entrada, que podem ser quaisquer valores entre positivo e infinito negativo, e a saída é padronizada para variar de 0-1 (HUANG et al., 2021). Geralmente o algoritmo é usado em redes multicamadas treinadas por retropropagação, principalmente porque esta função é fácil de diferenciar e é diferenciável. Além disso, tem excelentes propriedades matemáticas, e muitos algoritmos de otimização numérica podem ser usados diretamente para obter a solução ótima (XU et al., 2021).

LM é uma função de treinamento de rede que pode fornecer soluções numéricas que minimizam a não linearidade. Ao modificar os parâmetros durante a execução, este algoritmo pode perceber as vantagens de tanto o método de gradiente descendente quanto o algoritmo de Gauss-Newton e melhorar as deficiências de ambos os algoritmos (KUMALASARI et al., 2018). Em geral, esse algoritmo é a propagação de retorno mais rápido na caixa de ferramentas de rede e, embora use muita memória em computação, ainda é o algoritmo mais utilizado. O algoritmo LM tem velocidade de convergência de segunda ordem e menos interações, o que pode melhorar muito a velocidade de convergência e a estabilidade de o algoritmo (HAYKIN; NETWORK, 2004; HUANG et al., 2021).

Neste trabalho usamos a função de treinamento LM e função de transferência log-sigmoide para construir três sistemas artificiais eficazes e confiáveis, ou seja, redes neurais que podem prever a uniformidade do comprimento, comprimento e resistência de fibra. Entre eles, quando a estrutura do modelo de previsão de UNICIDEAL é 12–12–1, atinge a maior precisão ($R^2 = 0,90$); quando a estrutura de modelo de previsão de COMPIDEAL é 10–11– 1, tem a mais alta precisão ($R^2 = 0,91$); quando a estrutura do modelo de previsão de RESIDEAL é 9–10–1, atinge a mais alta precisão ($R^2 = 0,95$).

Os estabelecidos modelos de previsão de rede neural artificial podem melhorar a qualidade de fibra do algodoeiro otimizando a data de plantio com informações de temperatura média e pluviosidade.

REFERÊNCIAS

- ABDELHAMIED, M. R. *et al.* Prediction of Cotton Yarn's Characteristics by Image Processing and ANN. **Alexandria Engineering Journal**, v. 61, p. 3335-3340, 2022. DOI: <https://doi.org/10.1016/j.aej.2021.08.057>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S111001682100572X>. Acesso em: 30 jun 2022.
- ABRAPA. ASSOCIAÇÃO BRASILEIRA DOS PRODUTORES DE ALGODÃO. **Algodão no mundo**. Disponível em: <https://www.abrapa.com.br/Paginas/Dados/Algod%C3%A3o%20no%20Mundo.aspx>. Acesso em: 02 jul 2022.
- AMJAD, M. Relationship of Cotton properties and yarn properties. **Textech Millennium Issue**, National College of Textile Engineering, Faisalabad, Paquistão. p. 102-104, 1999. Disponível em: <https://iopscience.iop.org/article/10.1088/1757-899X/459/1/012057/pdf>. Acesso em: 15 nov 2021.
- BARBOSA, C. D. *et al.* Artificial neural network analysis of genetic diversity in *Caricapapaya* L. **Crop Breeding and Applied Biotechnology**, v.11, p. 224-231, 2011. <https://doi.org/10.1590/S1984-70332011000300004>. Disponível em: <https://www.scielo.br/j/cbab/a/JkCDNmYGwVM9jfh456g7TbT/?lang=en>. Acesso em: 25 mar 2022.
- BARROSO, L. M. A. *et al.* Uso do método de eberhart e russell como informação a prioripara aplicação de redes neurais artificiais e análise discriminante visando a classificaçãode genótipos de alfafa quanto à adaptabilidade e estabilidade. **Revista Brasileira de Biometria**, v.31, p. 176-188, 2013. DOI: Disponível: http://jaguar.fcav.unesp.br/RME/fasciculos/v31/v31_n2/A1_Lais_FAbiano.pdf. Acesso em: 22 nov 2021.
- BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. **Neural Network Toolbox TM User's Guide How to Contact MathWorks**. Natick: The MathWorks, Inc, 2015. Disponível em: http://cda.psych.uiuc.edu/matlab_pdf/nnet.pdf. Acesso em: 13 ago 2021.
- BECHELIER, B. Modernização na classificação do algodão. 2004. Disponível em: http://www.iam.gov.mz/IMG/pdf/Modernisacao_da_classificacao_do_algodao_em.pdf. Acesso em: 14 Ago 2015.
- BRADOW, J.M.; DAVIDONIS, G.H. Effect of environment on fiber quality. In: STEWART, J.M.; OOSTERHUIS, D.M.; HEITHOLT, J.; MAUNEY, J.R. (Eds.). **Physiology of Cotton**, Springer, p. 229-245, 2010. DOI: https://doi.org/10.1007/978-90-481-3195-2_21. Disponível em: https://link.springer.com/chapter/10.1007/978-90-481-3195-2_21. Acesso em: 01 set 2021.
- BRAGA, A. P. *et al.* **Redes Neurais Artificiais - Teoria e Aplicações** (2nd ed.). Rio de Janeiro: LTC, 2011.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Instrução normativa nº 63**, de 05 de dezembro de 2002. Brasília, 2002. Disponível em: <https://sistemasweb.agricultura.gov.br/sislegis/action/detalhaAto.do?method=visualizar>

AtoPortalMapa&chave=1481600449. Acesso em: 01 set 2022.

BROUGHTON, R. M. *et al.* Mechanism of yarn failure. **Textile Research Journal**, 62:131-134, 1992. DOI: <https://doi.org/10.1177/004051759206200302>.

Disponível em:

<https://journals.sagepub.com/doi/abs/10.1177/004051759206200302?journalCode=trjc>. Acesso em: 13 fev 2022.

CARDOSO, D. B. O. *et al.* Colored fiber cotton in the Uberlândia region using artificial neural networks for yield assessment. **Genetics and Molecular Research**, v. 18, p. 13, 2019. DOI: <https://doi.org/10.4238/gmr18104>. Disponível: <https://www.geneticsmr.com/articles/colored-fiber-cotton-uberl-ndia-region-0>. Acesso em: 04 abr 2021.

CARDOSO, D. B. O. *et al.* Variabilidade genética e coeficiente de determinação em genótipos de algodoeiro quanto a qualidade da fibra. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, v. 10, p. 66-71, 2015. DOI: <https://doi.org/10.18378/rvads.v10i3.3618>. Disponível em: <https://www.gvaa.com.br/revista/index.php/RVADS/article/view/3618>. Acesso 22 nov 2021.

CARVALHO, L. P. *et al.* Estabilidade e adaptabilidade de genótipos de algodão de fibracolorida quanto aos caracteres de fibra. **Ciência Rural**, v. 45, p. 598-605, 2015. DOI: <https://doi.org/10.1590/0103-8478cr2013023>. Disponível em: scielo.br/j/cr/a/YLnCDZLC98rMhPm7Qnw9tfP/abstract/?lang=pt. Acesso: 29 set 2021.

CHANELME J.L. **Manual de Beneficiamento do Algodão**, AMPA (Associação Matogrossense dos Produtores de Algodão) e IMAmt (Instituto Matogrossense do Algodão), Cuiabá, MT, Brasil, p. 367, 2014. Disponível em: <https://imamt.org.br/wp-content/uploads/2014/07/Manual-binder.pdf>. Acesso em: 30 jan 2022.

CHANELME, J. L. A qualidade da fibra de algodão em relação a seus mercados. In: MORESCO, E. (Org.) **Algodão: pesquisas e resultados para o campo**. Cuiabá: Facual, p.327-358, 2006.

CHIA, K. S. *et al.* Prediction of soluble solids content of pineapple via non-invasive lowcost visible and shortwave near infrared spectroscopy and artificial neural network. **Biosystems Engineering**, v. 113, p. 158-165, 2012. DOI: <https://doi.org/10.1016/j.biosystemseng.2012.07.003>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1537511012001201>. Acesso em: 11 jun 2021.

CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO. Séria histórica das safras: **Algodão**. Brasília: Companhia Nacional de Abastecimento. 2022. Disponível em: <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras>. Acesso em: 02 jul. 2022.

COTTON INCORPORATED. **Did you know?**. Disponível em: <https://www.cottoninc.com/cotton-production/ag-resources/cotton-crop-market-news>. Acesso em 14 jun.

2022.

COUTINHO, C. R. *et al.* Produtividade e qualidade de fibra de cultivares de algodoeiro (*Gossypium hirsutum* L.) na região do semiárido mineiro. **Essentia - Revista de Cultura, Ciência e Tecnologia da UVA**, v.2, p. 16, 2015. Disponível em: <https://essentia.uvanet.br/index.php/ESSENTIA/article/view/21>. Acesso em: 30 nov 2021.

GHAREHAGHAJI, A. A. *et al.* Analysis of two modeling methodologies for predicting the tensile properties of cotton covered nylon core yarns. **Textile Research Journal**, v.77, p. 565–571, 2007. DOI: <https://doi.org/10.1177/0040517507078061>. Disponível em: <https://journals.sagepub.com/doi/abs/10.1177/0040517507078061?journalCode=trjc>. Acesso em: 08 fev 2022.

GHOSH, A. *et al.* Predictive models for strength of spun yarns: An overview. **AUTEX Research Journal**, v.5, p. 20–29, 2005. Disponível em: https://www.researchgate.net/publication/236108456_Predictive_Models_of_Yarn_Strength_An_Overview. Acesso em 05 jan 2022.

GOH, G. *et al.* Multimodal neurons in artificial neural networks. **Distill**, v. 6, p. e30, 2021. Disponível em: <https://openai.com/blog/multimodal-neurons>. Acesso em: 02 fev 2022.

HAGHVERDI, A. *et al.* Prediction of cotton lint yield from phenology of crop indices using artificial neural networks. **Computers and Electronics in Agriculture**, v. 152, p.186-197, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.07.021>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169918307166>. Acesso em: 09 nov 2021.

HAYKIN, S. **Neural Networks and Learning Machines** (3rd ed.). Hamilton: Pearson -Prentice Hall, 2008. Disponível em: <https://dokumen.pub/neural-networks-and-learning-machines-3rd-ed-9780131471399-0131471392.html>. Acesso em: 11 fev 2022.

HUANG, X. *et al.* Using artificial neural network in predicting the key fruit quality of loquat. **Food Science & Nutrition**, v. 9, p. 1780-1791, 2021. Doi: <https://doi.org/10.1002/fsn3.2166>. Disponível em: https://www.researchgate.net/publication/348896627_Using_artificial_neural_network_in_predicting_the_key_fruit_quality_of_loquat. Acesso em: 13 set 2021.

JACKOWSKA-STRUMILLO, L. *et al.* Neural model of the spinning process for predicting selected properties of flax/cotton yarn blends. **FIBRES & TEXTILES in Eastern Europe**, v.12, p. 17–21, 2004. Disponível em: http://www.fibtex.lodz.pl/48_07_17.pdf. Acesso em: 10 dez 2021.

KHADDAM, H. S.; AHMAD, G. G. A method to evaluate the diameter of carded cottonyarn using image processing and artificial neural networks. **The Journal of The TextileInstitute**, v. 113, p. 1648-1657, 2022. DOI: <https://doi.org/10.1080/00405000.2021.1943259>. Disponível em:

<https://www.tandfonline.com/doi/abs/10.1080/00405000.2021.1943259?journalCode=tjti20>. Acesso em: 15 abr 2021.

KOHEL, R. J. Cotton germplasm resources and the potential for improved fibre production and quality. In: Basra, A. S. Cotton Fibers. **The Haworth Press**, New York, EUA. p.167-182, 1999.

KRIEG, D.R.; HEQUET, E.F. Fiber quality variation within a cotton plant as affected bygenetics and environment. **Proc. Beltwide Cotton Conferences**, National Cotton Council, January 4-7, 2005, New Orleans LA, USA, p. 6, 2005.

KUMALASARI, R. *et al.* Location of Sinabung volcano magma chamber on 2013 usinglavenberg-marquardt inversion scheme. In: **Journal of Physics: Conference Series**. IOPPublishing, p. 12182, 2018. DOI: <https://doi.org/10.1088/1742-6596/1013/1/012182>. Disponível em: <https://ui.adsabs.harvard.edu/abs/2018JPhCS1013a2182K/abstract>. Acesso em: 12 jan 2022.

LAN, H. *et al.* A nondestructive testing method for soluble solid content in Korla fragrantpears based on electrical properties and artificial neural network. **Food Science & Nutrition**, v. 8, p. 5172-5181, 2020. DOI: <https://doi.org/10.1002/fsn3.1822>. Disponível: <https://onlinelibrary.wiley.com/doi/full/10.1002/fsn3.1822>. Acesso em: 07 jan 2022.

LIMA, J. J.; BELOT, J. L. A fibra de algodão: qualidade e classificação. In: **Manual deBoas Práticas de Manejo do Algodoeiro em Mato Grosso 4ª Edição**. Cuiabá, Mato Grosso, IMA-MT, p. 340-351, 2020.

NASCIMENTO, M. *et al.* Artificial neural networks for adaptability and stability evaluation in alfalfa genotypes. **Crop Breeding Applied Biotechnology**, v.13, p. 152-156, 2013. DOI: <https://doi.org/10.1590/S1984-70332013000200008>. Disponível em: <https://www.scielo.br/j/cbab/a/YCVjBsdj9PPxTQwmYN53G9b/?lang=en>. Acesso em: 16 jan 2022.

REDDY, K.R. *et al.* Temperature regime and carbom dioxide enrichment after cotton bolldevelopment and fiber properties. **Agronomy Journal**, v.91, p.851-858, 1999. DOI: <https://doi.org/10.2134/agronj1999.915851x>. Disponível em: <https://acess.onlinelibrary.wiley.com/doi/10.2134/agronj1999.915851x>. Acesso em: 30 jan 2022.

SALGADO, C.C. *et al.* Melhoramento genético do algodoeiro visando à qualidade da fibra. In: SILVA, J.C.; SILVA, A.A.S.; ASSIS, R.T.; FRAVET, P.R.F. (Org.) **Agronegócio sustentável**. Uberlândia: Composer, p.147-172, 2015.

SANTANA, J. C. F. *et al.* Características tecnológicas da fibra com ênfase na fiabilidadede cultivares de algodão herbáceo do Mercosul. **Revista Brasileira de Oleaginosas e Fibras**, v.2, p.2, 1998.

SHABANI, A. *et al.* Using the artificial neural network to estimate leaf area. **Scientia Horticulturae**, v. 216, p. 103-110, 2017. DOI:

<https://doi.org/10.1016/j.scienta.2016.12.032>. Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S0304423816306720>. Acesso em: 17 fev 2022.

SILVA JÚNIOR, E. G. *et al.* Cotton genotypes selection through artificial neural networks. **Genetics and Molecular Research**, v. 16, p.223, 2017. DOI: <https://doi.org/10.4238/gmr16039798>. Disponível: <https://www.geneticsmr.com/articles/cotton-genotypes-selection-through-artificial-neural-networks>. Acesso em: 19 mar 2022.

SILVA, G. N. *et al.* Neural networks for predicting breeding values and genetic gains. **Scientia Agricola**, v.71, p. 494-498, 2014. DOI: <https://doi.org/10.1590/0103-9016-2014-0057>. Disponível: <https://www.scielo.br/j/sa/a/BKxth3Tptt6yPLgWSNPh4Bw/?format=pdf&lang=en>. Acesso em: 14 jan 2022.

SOUSA, P.S. *et al.* Efeito de lâminas de irrigação sobre algumas características de produção em condições controladas. **Bioscience Journal**, Uberlândia, v.25, p.90-95, 2009. Disponível em: <file:///D:/Users/USUARIO/Downloads/admin,+Biosci-2008-742.pdf>. Acesso em: 09 fev 2022.

UREYEN, M. E.; KADOGLU, H. The prediction of cotton ring yarn properties from afisfibre properties by using linear regression models. **FIBRES & TEXTILES in Eastern Europe**, v.15, p.63–67, 2007. Disponível em: https://www.researchgate.net/publication/283081367_The_Prediction_of_Cotton_Ring_Yarn_Properties_from_AFIS_Fibre_Properties_by_Using_Linear_Regression_Models. Acesso em: 22 mar 2021.

XU, A. *et al.* Applying artificial neural networks (ANNs) to solve solid waste-related issues: A critical review. **Waste Management**, v. 124, p. 385-402, 2021. DOI: <https://doi.org/10.1016/j.wasman.2021.02.029>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0956053X21000982#:~:text=A%20NNs%20were%20found%20to%20be,and%20microbial%20and%20dynamic%20processes>. Acesso em: 11 fev 2022.

YEATES, S. Efeitos do estresse hídrico na fisiologia do algodoeiro. In: ECHER, F.R. (Ed.). **O algodoeiro e os estresses abióticos: temperatura, luz, água e nutrientes**. Instituto Mato-Grossense do Algodão, Cuiabá, MT: p.63-77, 2014.