



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CAMPUS DE BLUMENAU
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA TÊXTIL - PGETEX

Francis Dalponte Voigt

**Desenvolvimento de uma rede neural artificial para maximizar a
reprodutibilidade de tingimento de tecidos de poliamida**

Blumenau

2024

Francis Dalponte Voigt

**Desenvolvimento de uma rede neural artificial para maximizar a
reprodutibilidade de tingimento de tecidos de poliamida**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Têxtil da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Mestre em Engenharia Têxtil.

Orientador: Prof. Ricardo Antonio Francisco Machado, Dr.

Coorientadora: Profa. Cintia Marangoni, Dra

Blumenau

2024

Voigt, Francis Dalponte

Desenvolvimento de uma rede neural artificial para maximizar a reprodutibilidade de tingimento de tecidos de poliamida / Francis Dalponte Voigt ; orientador, Ricardo Antonio Francisco Machado, coorientadora, Cintia Marangoni, 2024.

87 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Campus Blumenau, Programa de Pós-Graduação em Engenharia Têxtil, Blumenau, 2024.

Inclui referências.

1. Engenharia Têxtil. 2. inteligência artificial. 3. beneficiamento têxtil. 4. poliamida. 5. reprocessamento de malhas. I. Machado, Ricardo Antonio Francisco. II. Marangoni, Cintia. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Têxtil. IV. Título.

Francis Dalponte Voigt

Desenvolvimento de uma rede neural artificial para maximizar a reprodutibilidade de tingimento de tecidos de poliamida

O presente trabalho em nível de Mestrado foi avaliado e aprovado, em 30 de abril de 2024, pela banca examinadora composta pelos seguintes membros:

Prof. Ariovaldo Bolzan, Dr.
Instituição PósENQ/UFSC

Profa. Rita de Cássia Siqueira Curto Valle, Dra.
Instituição PGETEX/UFSC

Certificamos que esta é a versão original e final do trabalho de conclusão que foi julgado adequado para obtenção do título de mestre em Engenharia Têxtil



Coordenação do Programa de Pós-Graduação



Prof. Ricardo Antonio Francisco Machado, Dr.
Orientador

Blumenau, 2024

AGRADECIMENTOS

Gostaria de expressar gratidão à Deus, minha família, à Universidade Federal de Santa Catarina (UFSC) e à empresa Texneo. Além disso, não poderia deixar de mencionar minha profunda apreciação aos professores, colegas e membros da comunidade acadêmica pelo apoio e colaboração prestados. Aos meus orientadores, cuja orientação foi fundamental ao longo deste processo, e à banca examinadora, expresso minha gratidão pelos comentários e sugestões que contribuíram significativamente para o aprimoramento deste estudo. Que este trabalho possa efetivamente contribuir para o avanço do conhecimento. A todos que me apoiaram ao longo desta jornada, minha mais profunda gratidão por proporcionarem esta oportunidade de crescimento tanto acadêmico quanto pessoal.

RESUMO

A indústria têxtil brasileira é desempenha um papel essencial da economia do país, posicionando-se mundialmente como o quinto maior polo têxtil e o quarto no segmento de vestuário. No entanto, um dos desafios críticos enfrentados por esse segmento é o reprocessamento das malhas, gerando atrasos na entrega, impactos na qualidade e um aumento dos custos e do impacto ambiental. Diante disso, o objetivo desse estudo é identificar o reprocesso no tingimento de uma indústria têxtil por meio de padrões pré-estabelecidos utilizando uma rede neural. Para tanto, essa pesquisa foi realizada em parceria com uma empresa do setor, e concentrou-se na coleta, preparação e processamento de dados, além do treinamento e validação da rede neural. Especificamente, o foco incidiu sobre a produção de poliamida, onde cerca de 95% dos reprocessos são classificados como indefinidos, dificultando a identificação e solução precisa desses problemas. Utilizando dados de processo, uma rede neural foi treinada, a qual demonstrou capacidade de generalização, proporcionando previsões precisas. Esse estudo mostrou o potencial dessa abordagem para otimizar os processos industriais têxteis, sugerindo a expansão do conjunto de variáveis de entrada e a integração do modelo ao sistema de *Business Intelligence* da empresa, visando benefícios em qualidade, eficiência e custo. Estes resultados representam um passo inicial na utilização de aprendizado de máquina na indústria têxtil, indicando possibilidades futuras de aprimoramento e integração mais ampla dos resultados.

Palavras-chave: inteligência artificial, beneficiamento têxtil, poliamida, reprocessamento de malhas

ABSTRACT

The Brazilian textile industry plays an essential role in the country's economy, positioning itself worldwide as the fifth largest textile hub and the fourth in the clothing segment. However, one of the critical challenges faced by this sector is the reprocessing of fabrics, leading to delivery delays, quality impacts, and increased costs and environmental footprint. Therefore, the objective of this study is to identify the reprocess in the dyeing of a textile industry by means of pre-established patterns using a neural network. To this end, this research was carried out in partnership with a company in the sector, and focused on data collection, preparation and processing, as well as training and validation of the neural network. Specifically, the focus was on polyamide production, where about 95% of reprocesses are classified as undefined, making it difficult to accurately identify and solve these problems. Using process data, a neural network was trained, which demonstrated the ability to generalize, providing accurate predictions. This study showcased the potential of this approach to optimize textile industrial processes, suggesting the expansion of the input variable set and integration of the model into the company's Business Intelligence system, aiming for quality, efficiency, and cost benefits. These results represent an initial step in the use of machine learning in the textile industry, indicating future possibilities for improvement and broader integration of results.

Keywords: artificial intelligence, textile processing, polyamide, knitwear reprocessing

LISTA DE FIGURAS

Figura 1 - Fluxograma produtivo da cadeia têxtil.....	20
Figura 2 - Etapas atreladas ao beneficiamento têxtil de fibras naturais.	23
Figura 3 - Modelo geral do neurônio artificial.	32
Figura 4 - Rede neural de Hopfield.	33
Figura 5 - Estrutura de uma rede neural tipo caixa preta.	35
Figura 6 - Estrutura de um neurônio artificial, onde p = valores do processo ou dados de entrada; w = é denominada de peso e também representa a relevância de determinada variável de entrada no comportamento do processo; b = <i>bias</i> , que são os ajustes que se fazem necessários para corrigir algum desvio; F = é a função de ativação do neurônio e a = é o valor predito pelo neurônio.....	36
Figura 7 - Representação de uma rede neural que possui diversas entradas num neurônio artificial.	36
Figura 8 - Representação de uma rede neural com diversas camadas de neurônios artificiais interligados. Os estímulos são as entradas dos neurônios.	37
Figura 9 - Fase de treinamento da rede neural	39
Figura 10 - Malha com defeito de barramento.....	44
Figura 11 - Malha com defeito de manchas	44
Figura 12 - Malha com defeito de quebras	45
Figura 13 - Malha com defeito de tonalidade	45
Figura 14 - Fração de reprocesso em relação ao volume total de reprocesso (%) ...	49
Figura 15 - Variáveis identificadas para a entrada da RNA.....	51
Figura 16 - Programação utilizada para armazenamento dos dados.	56
Figura 17 - Programação utilizada para divisão dos conjuntos de dados.	56
Figura 18 - Programação utilizada para a criação da rede neural.....	57
Figura 19 - Comandos utilizados para o treinamento da rede neural.....	57
Figura 20 - Comandos utilizados para a validação da rede neural.....	58
Figura 21 - Comandos utilizados para o teste da rede neural.....	58
Figura 22 - Comandos utilizados para avaliar a rede neural	58
Figura 23 - Performance e supervisão do aprendizado.....	60
Figura 24 - Evolução do coeficiente de correlação.....	61
Figura 25 - Histograma de erro em relação ao valor predito e aos valores errados..	62
Figura 26 - Desempenho obtido em relação aos dados reais	63

Figura 27 - Comandos utilizados para previsões64

LISTA DE QUADROS

Quadro 1 - Características dos principais corantes empregados.....	27
Quadro 2 - Tipos de função de ativação	37

LISTA DE TABELAS

Tabela 1 - Síntese de trabalhos desenvolvidos com RNA e a indústria têxtil.....	40
Tabela 2 - Causas dos reprocessos gerados na produção de poliamida	50
Tabela 3 - Dados utilizados para a conversão numérica.....	55
Tabela 4 - Dados utilizados para previsão do resultado apresentado pela rede	64
Tabela 5 - Predição de novos valores de entrada	65

LISTA DE ABREVIATURAS E SIGLAS

AEG	Grupos amínicos terminais
CONMETRO	Conselho Nacional de Metrologia, Normalização e Qualidade Industrial
EDTA	Ácido etilenodiamino tetra-acético
PGETEX	Programa de Pós-graduação em Engenharia Têxtil
RNA	Rede Neural Artificial
UFSC	Universidade Federal de Santa Catarina

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVOS.....	18
1.1.1	Objetivo geral	18
1.1.2	Objetivos específicos	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	CADEIA PRODUTIVA TÊXTIL NO BRASIL.....	19
2.1.1	Importância da cadeia produtiva têxtil na economia brasileira	19
2.1.2	Etapas dos processos produtivos da cadeia têxtil	20
2.1.3	Matéria-prima empregada na indústria têxtil	21
2.2	BENEFICIAMENTO DAS INDÚSTRIAS TÊXTEIS.....	22
2.2.1	Pré-tratamento	23
2.2.2	Termofixação	24
2.2.3	Tingimento	25
2.2.3.1	<i>Corantes</i>	27
2.2.3.2	<i>Processos de tingimentos</i>	28
2.3	INTELIGÊNCIA ARTIFICIAL (IA).....	29
2.3.1	Rede neurais artificiais	31
2.3.1.1	<i>Características das redes neurais artificiais</i>	34
2.3.2	Inteligência artificial e o beneficiamento têxtil	40
3	MATERIAIS E MÉTODOS	43
3.1	DEFINIÇÃO DO PROBLEMA.....	43
3.1.1	Barramento	44
3.1.2	Manchas	44
3.1.3	Quebras	45
3.1.4	Tonalidade	45
3.2	COLETA E PREPARAÇÃO DOS DADOS.....	46
3.3	DESENVOLVIMENTO DA ARQUITETURA DA REDE NEURAL ARTIFICIAL	
	46	
3.3.1	Camada de Entrada	46
3.3.2	Camada Oculta	47
3.3.3	Camada de Saída	47
3.3.4	Funções de Ativação	47
3.3.5	Tipo de Rede	47

3.3.6	Algoritmo de Aprendizagem	47
3.4	TREINAMENTO E VALIDAÇÃO DA REDE NEURAL ARTIFICIAL.....	47
3.5	IMPLEMENTAÇÃO EM AMBIENTE DE PRODUÇÃO.....	48
4	RESULTADOS E DISCUSSÃO	49
4.1	RELEVÂNCIA DO PROBLEMA	49
4.2	AVALIAÇÃO DAS VARIÁVEIS DO PROCESSO PARA DEFINIÇÃO DOS DADOS DE ENTRADA DA RNA.....	50
4.2.1.1	<i>Fios de poliamida e elastano</i>	51
4.2.1.2	<i>Corantes</i>	52
4.2.1.3	<i>Banho e Insumos</i>	53
4.2.1.4	<i>Máquina</i>	53
4.2.1.5	<i>Processo</i>	54
4.2.2	Definição dos Dados de Entrada e Saída	54
4.3	CONSTRUÇÃO DA REDE NEURAL NO MATLAB.....	55
4.3.1	Definição dos dados de treinamento e teste	56
4.4	CRIAÇÃO DA REDE NEURAL E DEFINIÇÃO DA ARQUITETURA INICIAL	57
4.4.1	Treinamento da Rede Neural	57
4.4.2	Validação Cruzada e Ajuste de Parâmetros da arquitetura da rede	57
4.4.3	Teste da Rede neural artificial	58
4.4.4	Avaliação e ajuste da Rede neural artificial	58
4.5	DESEMPENHO DA REDE NEURAL TREINADA.	59
4.6	PREDIÇÕES PARA NOVOS DADOS DE ENTRADA.....	63
5	CONCLUSÕES	66
	REFERÊNCIAS	68

1 INTRODUÇÃO

A indústria têxtil brasileira apresenta um papel fundamental na economia do país, pois o Brasil se destaca como o quinto maior polo têxtil do mundo, sendo especialmente forte no segmento de vestuário, ocupando a quarta posição global nesta área. Além disso, o país é autossuficiente na produção de algodão, o que contribui para o abastecimento de matéria-prima para essa indústria, sendo notável por ser uma das cadeias mais completas do ocidente, abrangendo desde a produção da fibra até a comercialização no varejo. Essa integração vertical permite uma maior eficiência e controle de qualidade em todo o processo produtivo. Ademais, com a descoberta do pré-sal, o Brasil possui a oportunidade de se tornar um grande exportador mundial de fibras sintéticas (Abit, 2021).

O setor têxtil e de confecção teve um importante papel na história manufatureira mundial, antes mesmo do período industrial, onde os produtos eram fabricados artesanalmente. Porém, com o decorrer das revoluções industriais, o setor passou por transformações na configuração do modelo de negócio, substituindo operações de trabalho manual pelo fabril (Duarte, 2017). Com isso, a sociedade desenvolveu uma infraestrutura produtiva que se transformou em parques industriais para atender demandas de larga escala no mercado interno e externo. Esta infraestrutura atualmente constitui uma rede de infra segmentos produtivos independentes, tais como fiação, tecelagem, malharia, beneficiamento e confecção, constituindo a cadeia têxtil (Fujita; Jorente, 2015).

Dentro da infraestrutura têxtil, o setor de beneficiamento desempenha o papel fundamental de agregar valor e atender a uma ampla gama de necessidades desse segmento. No entanto, é importante ressaltar que esse processo enfrenta desafios, que o torna um ponto crítico em toda a cadeia de produtiva. Esse comportamento está atrelado a diversos fatores, dentre os quais pode-se ressaltar o longo ciclo de produção, a necessidade substancial de água para o processo, a liberação de substâncias tóxicas no meio ambiente, bem como o emprego de produtos químicos, como corantes, ácidos, soda cáustica e carbonato de sódio (Chen., 2017; KU et al., 2020). Esses fatores representam não apenas desafios ambientais, mas também preocupações com a segurança e a sustentabilidade do processo de beneficiamento.

A demanda global por produtos têxteis vem aumentando constantemente impulsionada pelo aumento da população e pelo desenvolvimento econômico, e por outro lado, torna-se evidente que as empresas estão cada vez mais conscientes e preocupadas com o impacto ambiental resultante de suas operações fabris (Kumar et al., et al. 2020, Zhang et al., 2021; Sandin; Peters, 2018). Como resposta a essa preocupação, várias áreas têm adotado abordagens de Produção Mais Limpa (P+L), bem como os conceitos da Indústria 4.0 e aplicando suas tecnologias nos processos produtivos para proporcionar inovação para suas empresas e torná-las mais competitivas (Kumar et al., 2020).

Além das questões relacionadas aos impactos ambientais, empresas têxteis enfrentam desafios em seus processos produtivos devido à necessidade de reprocessamento das malhas. O reprocesso acontece quando o produto apresenta variações em relação aos padrões de cor, toque, igualização, alongamento e elasticidade, toque e volume, comprometendo a eficiência da produção e afetando o atendimento aos clientes, por conta de atrasos no envio de produtos e por apresentar padrão diferente do desejado no momento da compra. Tal condição prejudica a imagem de uma empresa e reduz seu desempenho no mercado, além de representar aumento de custos e de impacto ambiental, ao consumir mais insumos e recursos para obtenção dos produtos.

Nesse sentido, a indústria têxtil está gerando demandas crescentes no mercado global e as tecnologias modernas beneficiam esse segmento com a automatização de processos longos e complexos, resultando em melhoria na velocidade, qualidade e custo da fabricação de têxteis (Schwarz; Kovačević, 2017). Segundo Falani et al. (2020), os avanços tecnológicos são um dos fatores estratégicos para gerar mudanças que contribuem para o aprimoramento de técnicas, ferramentas e utilização de novos insumos. Fujita e Jorente (2015) ressaltam que é necessário investimento em inovação tecnológica e na geração de novos conhecimentos, mediante desenvolvimento científico realizado no incentivo às pesquisas compartilhadas com a indústria têxtil.

Nesse cenário, a Inteligência Artificial (IA), em sua essência, permite contribuir para mitigar essa necessidade da indústria têxtil. A IA garante que os sistemas tomem decisões de forma independente, precisa e apoiada em dados digitais, o que, em uma visão otimista, multiplica a capacidade racional do ser humano de resolver problemas

práticos, simular situações, pensar em respostas ou, de forma mais ampla, potencializa a capacidade de ser inteligente.

Atualmente, o avanço da inteligência artificial está transformando a indústria têxtil, permitindo melhorias em diversas áreas, desde a concepção de design até a otimização da cadeia de suprimentos. Por meio da análise de dados, algoritmos de *machine learning* podem identificar padrões de consumo, prever tendências de mercado e personalizar produtos de acordo com as preferências dos consumidores. Além disso, a utilização de tecnologias com visão computacional e aprendizado profundo está revolucionando processos de controle de qualidade, possibilitando a detecção de defeitos em tecidos de forma mais precisa e eficiente. Assim, a integração da metodologia de inteligência artificial na indústria têxtil não apenas impulsiona a inovação e a eficiência, mas também abre caminho para uma produção mais sustentável e centrada no cliente (Rosa, 2021).

A medida que a tecnologia de aprendizado de máquina e inteligência artificial se tornou mais sofisticada e acessível nas últimas décadas, a aplicação de redes neurais nas indústrias têxteis ganhou destaque. Redes neurais começaram a ser usadas para uma variedade de fins, com maior enfoque no controle de qualidade, otimização de processos de fabricação, previsão de demanda e análise de padrões de consumo. Dessa forma, o setor tem utilizado redes neurais e outras técnicas de IA para aumentar a eficiência, qualidade e competitividade de seus produtos e processos. O principal benefício da aplicação de redes neurais especificamente no beneficiamento de produtos têxteis consiste na possibilidade de monitoramento, previsão e controle em tempo real. Porém, até o momento, é possível observar que as aplicações nesta etapa do processo focam na previsão da análise de cor, otimização dos parâmetros de tingimento e identificação de defeitos.

Diante do cenário exposto, a presente pesquisa possui como objetivo desenvolver uma rede neural capaz de tomar decisões de forma autônoma, identificando o reprocesso no tingimento de uma indústria têxtil por meio de padrões pré-estabelecidos. Além dos aspectos econômicos e sociais, o sucesso desta pesquisa aumenta a relevância ao contribuir para a economia de recursos (água, insumos, energia), com alto impacto ambiental, reforçando os compromissos já existentes na empresa e completando o tripé da sustentabilidade: social, econômico e ambiental.

1.1 OBJETIVOS

Os objetivos do presente trabalho foram divididos em objetivo geral e objetivos específicos.

1.1.1 Objetivo geral

Desenvolver e testar a viabilidade de uma rede neural artificial como ferramenta para identificar o reprocesso no tingimento de poliamida.

1.1.2 Objetivos específicos

1. Desenvolver um mapeamento de instabilidades do processo produtivo;
2. Estudar o fluxograma do processo de tingimento gerando um banco de dados utilizando o histórico de acontecimentos reais;
3. Apontar as variáveis que impactam no reprocesso;
4. Realizar a coleta de informações de um processo real de tingimento de poliamida, o qual esteve sujeito a reprocessos;
5. Utilizar o conjunto de dados coletados, verificar a integridade dos mesmos e adequá-los para que possam ser processados matematicamente;
6. Selecionar a rede neural que possa atender, de forma satisfatória, os objetivos do presente projeto;
7. Treinar e validar a rede neural com os dados reais do processo.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os pressupostos teóricos baseados na literatura nacional e internacional sobre o processo de beneficiamento das indústrias têxteis com ênfase na fibra de poliamida, reprocesso, e ferramentas de inteligência artificial.

2.1 CADEIA PRODUTIVA TÊXTIL NO BRASIL

2.1.1 Importância da cadeia produtiva têxtil na economia brasileira

Em linhas gerais, a cadeia produtiva têxtil é uma engrenagem vital na economia brasileira, contribuindo para o emprego, o desenvolvimento regional, as exportações, a sinergia entre diferentes setores e o avanço tecnológico. Seu papel fundamental na construção de uma economia robusta e diversificada torna-a um pilar inalienável no panorama econômico do Brasil.

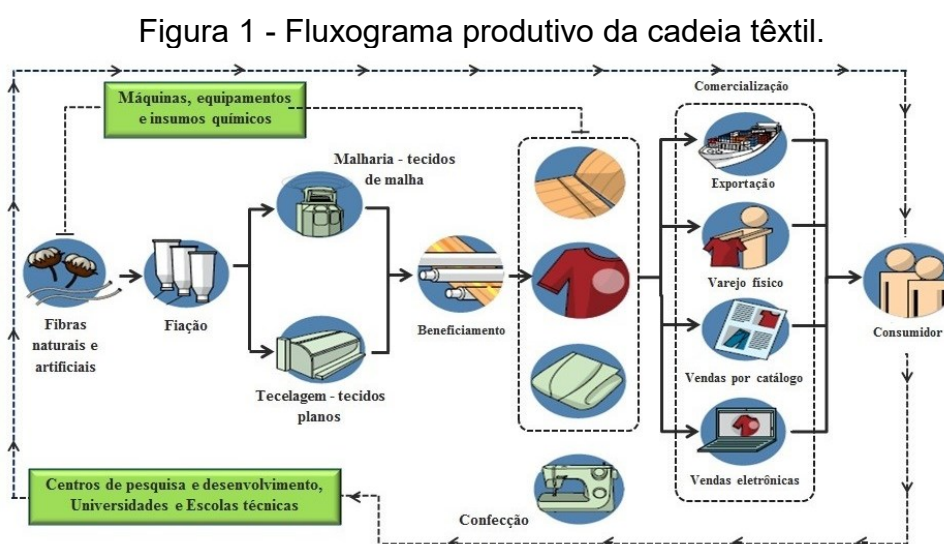
Diante deste contexto, o Brasil é a 5ª maior indústria têxtil do mundo e a 4º no segmento de vestuário, cuja produção média, em toneladas, é da ordem de 190 milhões em 2021 (Iemi, 2022). A indústria têxtil promove 1,36 milhões de empregos diretos e em 2020, representou 19,8% do total de trabalhadores alocados na produção industrial e 5% do valor total da produção da indústria brasileira de transformação (Iemi, 2022). Segundo o Instituto de Estudos e Marketing Industrial (2022), a cadeia têxtil brasileira abrange mais de 24,6 mil fábricas instaladas no país, sendo na ordem de 3.030 empresas têxteis e as demais de confecção. Junto desses dados, o Brasil é o único país do ocidente que possui a cadeia têxtil totalmente verticalizada (Abit, 2022).

Nesse sentido, devido à elevada relevância da indústria têxtil na economia nacional, esse setor é um grande gerador de renda e empregos para o país por demandar do uso intensivo de mão de obra. No ano de 2022, a indústria têxtil produziu 1,34 milhões de empregos formais e mais de 8 milhões de empregos indiretos, sendo 60% da mão de obra feminina (Iemi, 2022). Esse fato está atrelado a grande produção per capita de têxteis no Brasil, que atingiu 9,9 kg por habitante, com um consumo na

ordem de 13,3 kg/habitante, sendo que a referida diferença é atendida pelo mercado internacional (Abit, 2022).

2.1.2 Etapas dos processos produtivos da cadeia têxtil

O início do processo produtivo da cadeia têxtil é constituído primeiramente pelo processo de produção das fibras. Posteriormente, várias empresas de fiação de grande porte produzem os fios. Essas empresas empregam um grande volume de capital e tecnologia, são automatizadas e apresentam um baixo índice de mão de obra. Na etapa seguinte da cadeia, estão as indústrias de tecelagem, malharia e beneficiamento, que possuem características similares à da fiação (Falani et al., 2020). No último elo da cadeia encontram-se as confecções, que apresentam como característica baixo uso de capital e tecnologias, porém são muito intensas no uso de mão de obra. Por esses motivos são formadas em sua grande maioria, por micro e pequenas empresas, maior parte delas informais (Falani et al., 2020). Na Figura 1 apresenta-se, em forma de um fluxograma, as principais etapas do processo produtivo têxtil. Por questões de facilidade de entendimento, o fluxograma contém apenas as etapas macro, sem nenhum detalhamento.



Fonte: Adaptado de Pimentel; Lima (2011).

Dentro do fluxograma da cadeia têxtil, o processo de beneficiamento geralmente ocorre após a etapa de produção das fibras e antes da etapa de confecção das peças de vestuário ou produtos têxteis finais. O beneficiamento têxtil envolve uma

série de processos que preparam os materiais têxteis para a fabricação de produtos acabados. Esses ainda podem incluir várias etapas, tais como (i) tingimento onde o corante é aplicado para dar cor ao tecido ou fio, de acordo com as especificações do design; o (ii) acabamento que envolve processos como estampagem, calandragem e outros, que podem afetar a textura, brilho e toque do material; (iii) a lavagem onde os materiais são lavados para remover impurezas e produtos químicos residuais dos processos anteriores; (iv) o acabamento mecânico que pode incluir processos como corte, costura e acabamento das peças de vestuário ou produtos têxteis; e (v) inspeção de qualidade para finalizar o processo.

2.1.3 Matéria-prima empregada na indústria têxtil

As fibras têxteis representam a matéria-prima fundamental na indústria têxtil, passando por diversos processos de fabricação para serem transformadas em fios utilizados em uma ampla gama de produtos têxteis e aplicações industriais. De acordo com as diretrizes estabelecidas pelo Conselho Nacional de Metrologia, Normalização e Qualidade Industrial (Conmetro), as fibras têxteis englobam materiais de origem vegetal, animal, mineral, artificial ou sintética. Estas fibras se caracterizam pela relação significativa entre seu comprimento e diâmetro, assim como por suas propriedades de flexibilidade, suavidade, elasticidade, resistência, tenacidade e finura (baixo diâmetro), as quais as tornam adequadas para uso em produtos têxteis diversos.

Na cadeia de produção têxtil, uma vasta e diversificada gama de fibras é empregada, classificadas como naturais ou químicas. As fibras têxteis naturais compreendem aquelas encontradas na natureza, como o algodão (de origem vegetal), a lã (de origem animal) e o amianto (de origem mineral), além de outras fontes como o bagaço de cana, serragem, durian, fibra de palma, folhas de abacaxi, arroz e espiga de milho. Por outro lado, as fibras químicas são produzidas por processos industriais, subdividindo-se em artificiais e sintéticas. As fibras artificiais são obtidas a partir de polímeros naturais, como a celulose, enquanto as sintéticas utilizam polímeros sintetizados a partir de produtos petroquímicos primários, como eteno, propeno, benzeno e paraxileno. Além disso, existe uma categoria adicional denominada fibras artificiais sintéticas, as quais são produzidas a partir de polímeros naturais que, em sua forma original, não são utilizados na indústria têxtil, mas são modificados para

criar fibras adequadas para este fim. Exemplos dessas fibras incluem o liocel, a viscose e o modal, conhecidas por sua textura suave, brilho distinto e propriedades de absorção/dessorção únicas (Sinclar, 2014)

O Brasil possui uma significativa participação no mercado de fibras têxteis, com o consumo de fibra de algodão correspondendo a 84% do total, totalizando 1.042 milhão de toneladas. Em seguida, encontram-se os têxteis feitos de fibras artificiais e sintéticas, com 13% do consumo, seguido por outras fibras naturais com 3%. O país se destaca como o terceiro maior exportador mundial de algodão, o quinto maior consumidor e o líder em produtividade em áreas de cultivo sequeiro, alcançando uma média próxima de 1,7 milhão de toneladas de pluma de algodão por safra. Essa posição coloca o Brasil entre os cinco maiores produtores globais, ao lado da China, Índia, Estados Unidos da América e Paquistão (Iemi, 2021).

Após o algodão, o poliéster desponta como a fibra sintética mais consumida no setor têxtil, representando pouco mais de 50% da demanda total de fibras químicas. Pode ser empregado sozinho ou em combinação com outras fibras em diferentes proporções. Os tecidos resultantes são amplamente utilizados na confecção de uma variedade de artigos têxteis, incluindo vestuário, produtos para o lar e tecidos técnicos, sendo uma das opções de fibra com menor custo.

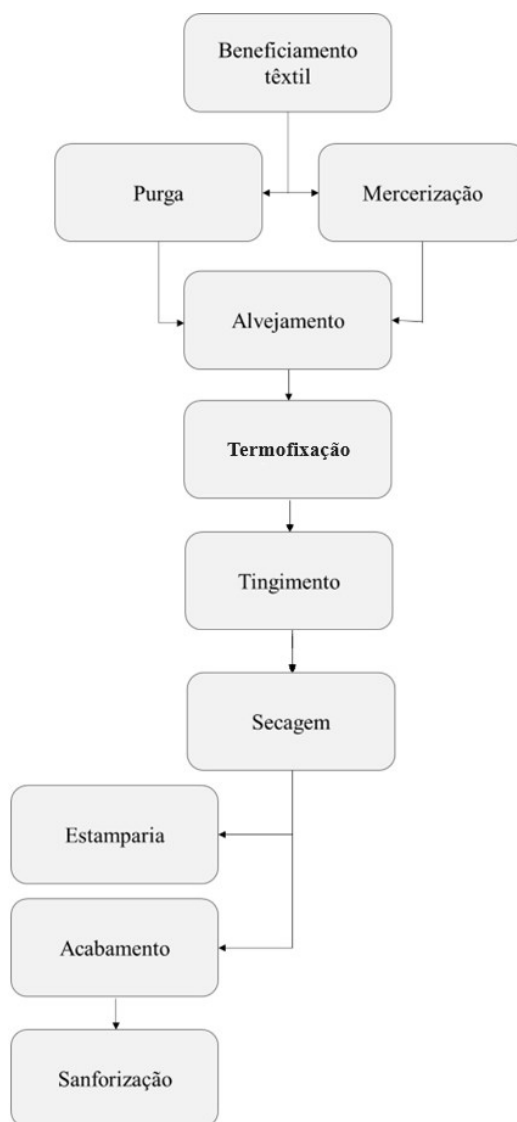
Por sua vez, a poliamida é reconhecida como a fibra sintética mais nobre, caracterizando-se por sua alta resistência mecânica, aproximadamente 3,5 vezes superior à do algodão, baixa absorção de umidade e capacidade de texturização, além de ser receptiva a diversos acabamentos têxteis. Na indústria têxtil, é amplamente empregada na produção de tecidos de malha para a confecção de meias, moda praia, lingerie e artigos esportivos (Iemi, 2021).

2.2 BENEFICIAMENTO DAS INDÚSTRIAS TÊXTEIS

O beneficiamento têxtil, de um modo geral, pode ser definido como o processo que agrega várias etapas com a finalidade de melhorar as características dos tecidos, fibras e fios, conferindo aos tecidos particularidades únicas. É basicamente composto por diferentes etapas e processos (Samsami et al., 2020). O beneficiamento têxtil consiste nas etapas de beneficiamento primário (preparação), beneficiamento secundário (tingimento) e beneficiamento terciário (acabamento). Na Figura 2 é apresentado um fluxograma com as principais etapas e processos

envolvidos no beneficiamento têxtil, especificamente para fibras naturais. Para o caso do beneficiamento de fibras sintéticas as etapas do beneficiamento têxtil não incluem a mercerização e alveamento.

Figura 2 - Etapas atreladas ao beneficiamento têxtil de fibras naturais.



Fonte: Adaptado de Madhu; Chakraborty, (2017).

2.2.1 Pré-tratamento

O beneficiamento primário ou pré-tratamento, consiste na etapa inicial do processo de beneficiamento. Todos os substratos têxteis necessitam deste tratamento antes de seguirem para os processos posteriores, como tingimento, estamparia ou acabamento. Madhu e Chakraborty (2017) ressaltam que como este beneficiamento é o primeiro tratamento aplicado no material têxtil (fio ou tecido), e possuem como

objetivo a obtenção de produto final com melhor aceitação no mercado. As operações a serem efetuadas seguem uma sequência e devem ser preservadas para garantir um bom resultado no processo

Este processo é conhecido também como purga ou fervura e é responsável pela remoção de óleos da fibra têxtil sintética. Para este fim são utilizados produtos emulgadores de óleo, também chamados de tensoativos ou detergentes, que podem ser produtos com características não iônicas ou aniônicas. Este processo é geralmente realizado em temperaturas de 50 a 60°C (Ketema; Worku, 2020).

Em linhas gerais, a remoção eficaz de impurezas ocorre com o emprego de 3-6% de hidróxido de sódio ou hidróxido de cálcio ou carbonato de sódio. Além disso, a escolha adequada dos auxiliares têxteis no banho alcalino é essencial para um bom processamento de purga. Estes incluem agentes sequestrantes ou quelantes, como o ácido etilenodiamino tetra-acético (EDTA), para solubilizar substâncias inorgânicas insolúveis presentes em água dura e surfactantes, como o lauril sulfato de sódio que serve como detergente, agente dispersante e agente emulsificante para remover ceras insaponificáveis (Barani, Montazer, 2008).

A purga também é aplicada em fibras sintéticas que adquirem tonalidade amarela devido ao superaquecimento ou ao acúmulo de impurezas durante a fabricação. Esse processo é mais suave em comparação com as fibras naturais (Broadbent, 2011). Nas fibras sintéticas, a lavagem é realizada com sabão ou detergentes contendo quantidades menores de alcalinos (0,1-0,2% de carbonato de sódio) (Vigo, 2002).

2.2.2 Termofixação

A termofixação pode ser considerada um pré-tratamento do tecido, pois pode ser realizada antes do tingimento com o objetivo de proporcionar estabilidade dimensional ao artigo. Este processo é realizado somente em fibras sintéticas como poliéster, poliamida, suas misturas e em artigos com elastano (Ruschioni; Alfieri, 2010).

Os parâmetros mais importantes na termofixação são temperatura, tempo e a tensão mecânica aplicada ao tecido. As mudanças causadas pela termofixação não são apenas mecânicas, mas também nas propriedades de tingimento das fibras sintéticas. A temperatura determina as propriedades de tingimento como segue: Com

o aumento da temperatura a proporção de regiões cristalinas diminui porque os cristalitos instáveis fundem e a massa polimérica recristaliza parcialmente. Quanto maior a proporção de regiões não cristalinas depois da termofixação, que também é influenciada pela taxa de resfriamento (resfriamento rápido reduz a recristalização), melhores serão as propriedades de tingimento posterior (Giordano, 2014).

Além de melhorar a resistência das fibras, a termofixação também pode ser usada para controlar outras propriedades, como a elasticidade e a absorção de umidade. Ao ajustar as condições de temperatura e tempo durante o processo de termofixação, os fabricantes podem personalizar as propriedades das fibras para atender a requisitos específicos de aplicação (Ruschioni; Alfieri, 2010).

É importante ressaltar que o processo de termofixação deve ser cuidadosamente controlado para evitar danos às fibras. Temperaturas muito altas ou tempos de exposição prolongados podem resultar em degradação das fibras, comprometendo suas propriedades mecânicas e estabilidade dimensional (Adanur, 2017).

2.2.3 Tingimento

O tingimento é um processo conduzido para conferir cor aos substratos têxteis, de forma homogênea com a utilização de corantes. Esse processo é conhecido também como beneficiamento secundário. Em linhas gerais, é dividido em três etapas mediadas por processos de migração, absorção e fixação do corante. Na primeira etapa o corante migra do meio em que se encontra diluído para a superfície da fibra. Posteriormente ocorre o processo de adsorção nas camadas superficiais do material têxtil e em seguida o corante se difunde no interior e fixa-se na fibra por diferentes tipos de ligações (iônicas, Van Der Waals, covalentes) dependendo do tipo do material empregado e do corante utilizado (Adanur, 2017).

A temperatura é um fator primordial nessas etapas devido a influência dos produtos químicos e a da ação mecânica causada pela agitação do banho de tingimento do substrato têxtil em processamento (Ketema; Worku, 2020). Além da temperatura, a velocidade de tingimento deve ser criteriosamente definida em forma de uma curva, considerando o substrato, produtos e máquina. Essa curva deve expressar o tempo de tingimento em função da porcentagem total de corante que ao interagir alcançará o equilíbrio, tanto quanto o tempo requerido para alcançar o

máximo de esgotamento. Muitos fatores críticos são importantes para a boa igualização e reprodutibilidade (Ketema; Worku, 2020).

Especialmente para o caso da poliamida, a temperatura desempenha um papel crucial no tingimento. Como a poliamida é termoplástica, amolece quando exposta a altas temperaturas, permitindo uma melhor absorção dos corantes. No entanto, é importante controlar a temperatura com precisão para evitar danos às fibras e garantir resultados de tingimento consistentes. Temperaturas muito altas podem resultar em deformação ou derretimento das fibras, enquanto temperaturas muito baixas podem levar a uma absorção inadequada de corantes (Zhang et al., 2023).

Em comparação com a lã, a difusão de corantes ácidos na poliamida é mais lenta e o número limitado de locais carregados na poliamida também pode causar problemas no tingimento da mistura de tons profundos, onde os corantes individuais competem por locais disponíveis. Sob estas condições, os corantes de difusão mais rápida podem bloquear a entrada de um segundo componente, e a tonalidade não é alcançada (Adanur, 2017).

A maior ou menor saturação da fibra depende da porcentagem de grupos amínicos terminais (AEG) e estes, nas fibras de poliamida são em número limitado. A saturação depende também do número de grupos sulfônicos existentes no corante e que reagirão com os grupos amínicos terminais. Quanto maior o número de grupos sulfônicos na molécula de um corante, menor a saturação: uma molécula de corante ocupará mais de um grupo amínico terminal. Assim um corante trissulfônico, ocupa três grupos amínicos terminais. Por isso, quando são combinados corantes com mono e trissulfônico, na mesma receita, há a tendência do corante monossulfônico fixar primeiro na fibra, ocupar os grupos amínicos (que são limitados) e bloquear a montagem do corante trissulfônico, que permanece no banho (Gondim, 2016)

A permanência do corante na fibra é afetada por vários fatores, dentre os quais pode-se destacar a (i) vibração da estrutura molecular da fibra, a cada momento, tomando novas configurações; (ii) durante o tingimento, constante bombardeio do corante pelas moléculas de água, dificultando sua fixação na fibra; (iii) com o aumento da temperatura do sistema, aumenta a vibração das moléculas da fibra e o bombardeio das moléculas de água (Ketema; Worku, 2020).

O reprocesso de poliamida na indústria têxtil ocorre principalmente em processos de tingimento, onde o objetivo é alterar a cor ou as propriedades físicas dos tecidos de poliamida. Este reprocesso pode ser necessário por diversas razões,

como correção de cor, melhoria na qualidade do tingimento, ajustes na tonalidade ou até mesmo para corrigir imperfeições que ocorreram durante o processo inicial (Su et al., 2007).

2.2.3.1 Corantes

Os corantes são compostos de moléculas que compreendem dois componentes chave, sendo o funcional e o cromóforo. O grupo cromóforo é responsável pela cor e o grupo funcional, que se liga as fibras do tecido. Existem muitos tipos de corantes e estes podem ser classificados por sua natureza química ou em relação a sua aplicação ao tipo de fibra (Kant, 2012).

Atualmente na indústria têxtil existem vários corantes sendo amplamente utilizados e podem ser classificados como corantes ácidos, corantes azóicos ou naftóis, corantes catiônicos, básicos ou citadinos, corantes diretos ou substantivos, corantes dispersos, corantes reativos, corantes à tina ou à cuba, corantes ao enxofre ou sulfurosos e pigmentos (Adanur, 2017). No Quadro 1 apresenta-se uma síntese descritiva desses corantes.

Quadro 1 - Características dos principais corantes empregados.

Tipo de corante	Características do corante
Diretos ou substantivos	<ul style="list-style-type: none"> - Compostos por azosulfonado que se ioniza em meio aquoso, tendo como componente colorido ou cromóforo um ânion; - Solúveis em água e com afinidade de tingimento das fibras celulósicas por meio de interações de Van der Waals, esta afinidade é aumentada com a adição de eletrólitos; - São aplicados em banho neutro ou levemente alcalino, próximo ou no ponto de ebulição, sendo necessária adição de cloreto ou sulfato de sódio em quantidades e intervalos de tempo apropriados.
Dispersos	<ul style="list-style-type: none"> - Podem ser utilizados no tingimento de fibras de acetato, acrílico, aramida, modacrílica, olefinas, poliamidas, poli(cloreto de vinilideno), poliéster e triacetato; - São não iônicos e quase sempre apresentam solubilidade baixa, necessitando de preparação específica para atingir uma dispersão estável, o procedimento pode ser com água contendo um agente de dispersão aniônico para diminuir o tamanho das partículas do corante, sendo comercializados na forma de pastas ou pós.
Reativos	<ul style="list-style-type: none"> - Popular para o tingimento de algodão, devido a ampla gama de cores, procedimentos de aplicação flexíveis, tonalidades brilhantes e propriedades completas de cores sólidas no resultado dos tingimentos;

	- Contém um grupo reativo com capacidade de formar ligações covalentes com os grupos hidroxila das fibras celulósicas, com grupos amino, hidroxila e tióis das fibras proteicas e grupo amino das poliamidas. Nesta classe de corante a reação química ocorre diretamente por meio da substituição do grupo nucleofílico pelo grupo hidroxila da celulose.
Ácidos	- São amplamente utilizados para tingir uma variedade de fibras, incluindo lã, seda, nylon e outras fibras sintéticas; - Os corantes ácidos oferecem uma ampla gama de cores vibrantes e intensas, permitindo uma infinidade de opções de design e estilo para os tecidos produzidos; - Possuem excelente afinidade por uma variedade de substratos têxteis, garantindo uma boa fixação e penetração nas fibras, resultando em cores duráveis e resistência à lavagem

Fonte: Adaptado de Kant (2012).

2.2.3.2 *Processos de tingimentos*

Os artigos têxteis podem ser tingidos por meio de processos contínuos ou descontínuos (Ketema; Worku, 2020). O processo de tingimento a ser escolhido é um fator chave pois é uma das fases determinantes do sucesso comercial dos produtos têxteis, atendendo características básicas de um produto, tais como a padronização da cor, elevado grau de solidez em relação à luz, lavagem e transpiração, tanto inicialmente quanto após uso prolongado (Samsami et al., 2020).

No processo de tingimento descontínuo, também conhecido como processo por esgotamento, o corante é deslocado do banho para a fibra, sendo que o banho de tingimento é mais volumoso que o peso do substrato (Samsami et al., 2020). O tecido fica longo tempo em contato com o banho de tingimento, e a solução de corante entra em contato com o tecido que tem sua tensão superficial diminuída pela aplicação de tensoativos. Assim, o contato entre o banho e o substrato, bem como a velocidade e migração do corante influenciam a equalização do tingimento (Kant, 2012). Diversas são as formas de proporcionar contato entre o material a ser tingido e o corante, comumente os meios de circulação mais utilizados são: (i) material têxtil em movimento e o banho parado; (ii) material têxtil parado e o e o banho formando movimentos circulares e (iii) tanto o material têxtil quanto o banho em movimento (Salem, 2010).

Cabe ressaltar que no processo descontínuo de tingimento a velocidade de montagem do corante na fibra depende de alguns fatores, que podem retardar ou

acelerar esta montagem. São estes: temperatura, tempo, pH do meio, eletrólitos, aceleradores e retardantes e relação de banho (Kant, 2012).

Já em relação ao processo de tingimento contínuo, o corante penetra na fibra com o auxílio de uma força mecânica, onde o tecido é pressionado por dois rolos após ter passado por um banho de corante. Nesse processo a solução é aplicada por impregnação sobre o material têxtil e espremida mecanicamente, sendo que na sequência o tingimento pode ser fixado por calor seco, calor úmido, repouso a frio, repouso a quente ou banho novo (Uddin, 2021).

Dessa forma, ao comparar os dois processos de tingimento pode-se identificar que o tingimento descontínuo é um processo mais tradicional, onde a coloração é aplicada em lotes menores de tecido. Nesse método, a tintura é feita em cubas ou máquinas específicas, onde o tecido é mergulhado na solução de corante por um período determinado. Esse processo é mais flexível para produzir cores personalizadas e permite ajustes durante o tingimento. No entanto, requer mais mão de obra e pode gerar mais resíduos devido à necessidade de enxágue entre as etapas (Samsami et al., 2020). Por outro lado, o tingimento contínuo é um processo que apresenta mais automatização e é realizado enquanto o tecido está em movimento contínuo. Geralmente, é usado para tingir grandes volumes de tecido de forma mais rápida e eficiente. Nesse método, o tecido passa por uma série de compartimentos ou tanques, onde a tintura é aplicada continuamente enquanto o tecido se move ao longo do sistema. Isso é ideal para produção em massa, mas pode ser menos flexível em termos de ajustes de cor durante o processo (Samsami et al., 2020).

A maioria das indústrias utiliza processos descontínuos e, no caso da poliamida, por ser uma malha mais sensível, geralmente utilizam-se máquinas de tingimento do tipo jet ou overflow. Essas máquinas são projetadas para lidar com tecidos delicados, garantindo uma movimentação suave da malha durante o processo de tingimento, minimizando assim o risco de danos ao tecido.

2.3 INTELIGÊNCIA ARTIFICIAL (IA)

A IA representa o ápice da inovação tecnológica, sendo um campo multidisciplinar que busca replicar a capacidade humana de aprendizado, raciocínio e tomada de decisões através de algoritmos e sistemas computacionais. Fundamentada em conceitos como *machine learning*, redes neurais e processamento de linguagem

natural, a IA tem conquistado um papel central em diversas esferas da vida moderna (SU et al., 1993). Sua capacidade de analisar grandes volumes de dados, identificar padrões complexos e tomar decisões autônomas está redefinindo indústrias, impulsionando a automação e transformando a maneira como interagimos com a tecnologia, desde assistentes virtuais a sistemas de diagnóstico médico avançados. A rápida evolução e aplicação da IA estão moldando não apenas a era da tecnologia, mas também redefinindo as fronteiras do conhecimento humano e suas aplicações práticas (Mukherjee; Bha, 2023).

Os pressupostos teóricos sobre IA são fundamentais para compreender a base conceitual por trás do desenvolvimento e aplicação desse cenário. Esses pressupostos formam o alicerce teórico que orienta a criação de sistemas e algoritmos inteligentes (Schädler e Wysotzki, 1999). Englobam áreas como o aprendizado de máquina que se concentra na capacidade dos sistemas de aprender e melhorar com a experiência; a lógica computacional que visa entender como os sistemas podem representar o conhecimento e raciocinar de maneira lógica; e as redes neurais que se inspiram no funcionamento do cérebro humano para criar modelos de computação altamente eficientes (Himmelblau, 2008). A compreensão desses pressupostos é crucial para explorar não apenas o potencial, mas também os limites e desafios da IA em diversos campos de aplicação, incluindo o setor têxtil (Sikka et al., 2022).

Na indústria têxtil, algumas áreas já vêm sendo transformadas pela aplicação de IA. Na produção e manufatura, a programação de máquinas, o controle de qualidade, a manutenção preditiva e a gestão de estoque podem ser realizadas com otimização de processos. No design e desenvolvimento de produtos, a IA auxilia na criação de padrões, estampas e personalizações com base em dados de mercado e preferências de consumidores. Da mesma forma, o setor de marketing e vendas se beneficia desta tecnologia para análise de dados de mercado e tendências e, a gestão de cadeia de suprimentos para otimizar a logística, prever demanda por matérias-primas e gerenciar fornecedores. Redes neurais, algoritmos de aprendizado de máquina, reconhecimento de padrões de imagens, redes de análise de risco e segurança são exemplos de técnicas empregadas. Porém, o uso desta tecnologia em aplicações do beneficiamento têxtil que não envolvem a programação de máquinas ainda é incipiente e precisa ser desenvolvido.

2.3.1 Rede neurais artificiais

Redes neurais artificiais (RNA) são elementos computacionais inspirados em neurônios biológicos, que conectados em rede podem reproduzir algumas características de processos inteligentes (Ramesh et al., 2004). A Aprendizagem com RNA, emergiu como uma estrutura dominante atualmente, gerando avanços em uma ampla gama de aplicações, incluindo visão computacional, processamento de linguagem natural e jogos estratégicos (Smirnov et al., 2014). Algumas ideias-chave nesse campo podem ser rastreadas até chegar no cérebro humano sendo que atualmente existe um contínuo intercâmbio de ideias da neurociência para o campo da inteligência artificial (Hassabis et al., 2017).

Simultaneamente, o aprendizado sobre IA oferece ferramentas para a neurociência de sistemas. De fato, os avanços em visão computacional, especialmente RNA, revolucionaram o processamento de dados de imagens e vídeos. Comportamentos não controlados ao longo do tempo, como micro-movimentos de animais em um experimento laboratorial, agora podem ser rastreados e quantificados de forma eficiente com a ajuda dessa tecnologia (Mathis et al., 2018).

Inspirados na habilidade apresentada pelos seres humanos e outros animais no desempenho de funções como o processamento de informações sensoriais e a capacidade de interação com ambientes pouco definidos, os engenheiros estão preocupados em desenvolver sistemas artificiais capazes de desempenhar tarefas semelhantes. Habilidades como capacidade de processamento de informações incompletas ou imprecisas e generalização são propriedades desejadas em tais sistemas (Liu et al., 2020).

Nesse sentido, a RNA são técnicas computacionais que têm capacidade de solucionar problemas por intermédio de circuitos simples que simulam o funcionamento e o comportamento do cérebro humano. Apresentam um modelo inspirado na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência, ou seja, aprendendo, errando e fazendo descobertas. Uma rede neural artificial pode ter centenas ou até milhares de unidades de processamento, enquanto o cérebro de um mamífero pode conter muitos bilhões de neurônios (Liu et al., 2020)

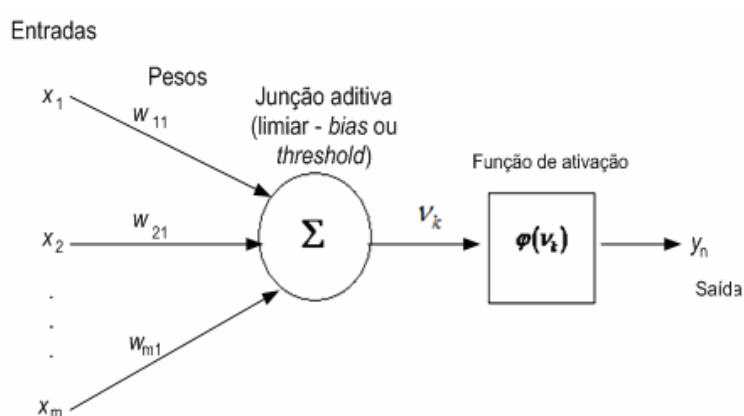
No entanto, é importante ressaltar que existem diferenças entre a célula nervosa humana e o modelo de neurônio artificial ainda que o princípio de

transferência das informações seja o mesmo. Analogamente ao cérebro humano, as RNA têm a capacidade de interagir com o meio externo e adaptar-se a ele. Essas características conferem as RNA uma importância multidisciplinar, razão pela qual essa ferramenta vem ganhando destaque em diferentes áreas do conhecimento, tais como engenharia, matemática, física, informática entre outras (Liu et al., 2020).

O modelo matemático do neurônio, e que engloba as principais características de uma rede neural biológica, paralelismo e alta conectividade, foi proposto em 1942 por McCulloch e Pitts, onde os pesquisadores projetaram a estrutura conhecida como a primeira rede neural mundialmente conhecida como modelo MCP (McCulloch-Pitts). O modelo MCP representa uma simplificação do neurônio biológico, que considera o neurônio como uma unidade de processamento de informações binárias, com várias entradas binárias e uma única saída binária, mostrando que essas unidades são capazes de executar diferentes operações lógicas.

Na Figura 3 apresenta-se o modelo geral do neurônio artificial, onde: x_1, x_2, x_n representam os sinais de entrada; w_1, w_2, \dots, w_n são os pesos ou conexões sinápticas; as bias representam o limiar de ativação do neurônio; u é a saída do combinador linear; f é a função de ativação (limita a saída do neurônio); y é o sinal de saída do neurônio.

Figura 3 - Modelo geral do neurônio artificial.

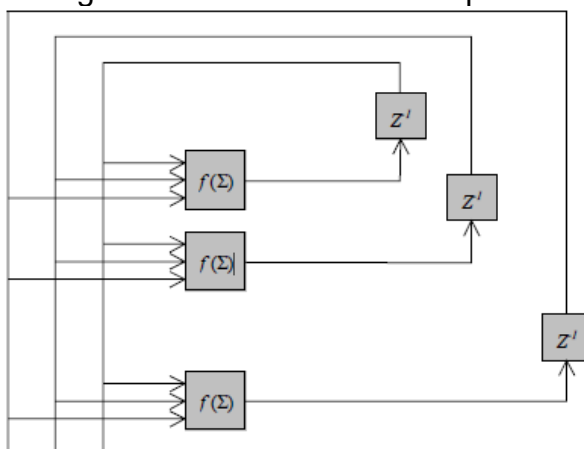


Fonte: Adaptado de Finocchio (2014).

A operação de uma célula em uma rede neural, geralmente, pode ser descrita da seguinte forma: (i) os sinais são apresentados à entrada; (ii) cada sinal é multiplicado por um peso, o qual indica sua influência na saída da célula; (iii) executa-se a soma ponderada dos sinais, o que produz um nível de atividade; (iv) quando este nível excede um limite, a unidade produz uma saída (Finocchio, 2014).

Ao longo do tempo, RNAs passaram por um processo de evolução. Primeiramente, em 1948, N. Wiener criou a palavra cibernética para descrever, de forma unificada, controle e comunicação nos organismos vivos e nas máquinas. Posteriormente, em 1949, D. O. Hebb apresentou uma hipótese a respeito da maneira com que a força das sinapses no cérebro se altera em resposta à experiência. Em particular, foi sugerido que as conexões entre células que são ativadas ao mesmo tempo tendem a se fortalecer, enquanto as outras conexões tendem a se enfraquecer. Esta hipótese passou a influir decisivamente na evolução da teoria de aprendizagem em redes neurais artificiais. Mais tarde, em 1957, Rosenblatt introduziu uma nova abordagem para o problema de reconhecimento de padrões com o desenvolvimento do perceptron. Esse mesmo pesquisador, também propôs um algoritmo para o ajuste dos pesos do perceptron e provou sua convergência quando os padrões são linearmente separáveis. A conclusão interessante na sequência adotada por Hopfield foi que tais estados de equilíbrio podem ser utilizados como dispositivos de memória, caracterizadas por conexões recorrentes, onde os neurônios podem estar conectados a si mesmos e a outros neurônios na rede (Figura 4). De forma distinta daquela utilizada pelos computadores convencionais, em que o acesso à informação armazenada se dá por meio de um endereço, o acesso ao conteúdo da memória de uma rede de Hopfield se dá permitindo que a rede evolua com o tempo para um de seus estados de equilíbrio. Tais modelos de memória são denominados memórias endereçáveis por conteúdo.

Figura 4 - Rede neural de Hopfield.



Fonte: Adaptado de Finocchio (2014).

Por volta de 1962, B. Widrow e seus colaboradores desenvolveram o ADALINE (*Adaptive Linear Element*). No entanto, o fato que efetivamente colocou a área de RNA como uma das prioritárias na obtenção de recursos foi o desenvolvimento de um método para ajuste de parâmetros de redes não-recorrentes de múltiplas camadas. Portanto, uma das arquiteturas mais empregadas é a rede Perceptron de Múltiplas Camadas, que utiliza como regra de aprendizagem o algoritmo *back propagation*, proposto em 1986 por Rumelhart, McClelland e Williams (Beale; Jackson, 1990).

2.3.1.1 *Características das redes neurais artificiais*

As características mais importantes das redes neurais artificiais são inúmeras, dentre as quais pode-se citar: (i) a capacidade de aprender as relações entre um conjunto de dados de entrada, também chamados de exemplos de treinamento, e com isso melhorar o seu desempenho; (ii) capacidade de generalizar o aprendizado para novos exemplos; (iii) capacidade de extrair a essência de um conjunto de dados e aprender a partir de informações incompletas; (iv) robustez e tolerância a falhas (a eliminação de alguns neurônios não afeta substancialmente o seu desempenho global); (v) flexibilidade (pode ser ajustada a novos ambientes por meio de um processo de aprendizagem, sendo capaz de aprender novas ações com base na informação contida nos dados de treinamento); (vi) processamento de informação incerta; e (vii) paralelismo - um imenso número de neurônios está ativo ao mesmo tempo. Não existe a restrição de um processador que obrigatoriamente trabalhe uma instrução após outra (Finochio, 2014).

As características acima tornam as redes neurais especialmente atrativas para aplicações em sistemas não lineares e que possuem um grande volume de parâmetros, os quais podem sofrer variações temporais, como é o caso do beneficiamento têxtil. As RNA, podem, ainda, serem classificadas de acordo com a sua arquitetura, por exemplo:


1. Perceptron
2. Feed Forward Neural Network
3. Multilayer Perceptron
4. Convolutional Neural Network
5. Radial Basis Functional Neural Network

6. Recurrent Neural Network
7. LSTM – Long Short-Term Memory
8. Sequence to Sequence Models
9. Modular Neural Network

As classificações foram citadas em inglês de forma proposital, pois é a forma como se costuma referenciar. Adicionalmente, as redes neurais ainda podem ser combinadas entre si, retroalimentadas e ainda possuírem conhecimento prévio.

As redes neurais que possuem uma estrutura tal qual possui, por exemplo, 3 camadas, sendo a primeira cada, a de entrada, a segunda camada (camada intermediária), a de processamento e, a terceira camada, a de saída, costuma ser chamada de rede neural tipo caixa preta (black box neural network). Por questões de objetividade, neste documento é abordado somente as redes neurais artificiais tipo caixa preta, uma vez que esta é a forma comum de abordar RNAs quando há informações suficiente do processo para inserir conhecimento prévio na estrutura que será utilizada. Na Figura 5 é possível visualizar tal tipo de estrutura.


Figura 5 - Estrutura de uma rede neural tipo caixa preta.



Fonte: Adaptado de Finochio (2014).

A rede neural possui elementos denominados de neurônios, os quais podem ser completamente ou parcialmente interligados. Na Figura 6 pode-se ver a estrutura de um neurônio artificial.

Figura 6 - Estrutura de um neurônio artificial, onde p = valores do processo ou dados de entrada; w = é denominada de peso e também representa a relevância de determinada variável de entrada no comportamento do processo; b = *bias*, que são os ajustes que se fazem necessários para corrigir algum desvio; F = é a função de ativação do neurônio e a = é o valor predito pelo neurônio.



Fonte: Adaptado de Finochio (2014).

Na Equação 1 é representada a função de ativação do neurônio, F :

$$a = F(w.p + b) \quad (1)$$

Onde:

a = dados de saída ou valores preditos

p = dados de entrada


w = pesos

b = *bias*

F = função de ativação

Os parâmetros w e b devem ser ajustados de forma a representarem com relativa precisão os dados do processo. Na fase de ajuste, afirma-se que a rede neural está sendo treinada, que nada mais é que o emprego de um algoritmo de otimização para ajustar os valores de w e b de tal forma a predizer os dados de saída (a) com o menor desvio possível dos valores de entrada. É aqui que entram os termos de aprendizado de máquina (*Machine Learning*). Os neurônios também podem possuir diversas entradas, como mostrado na Figura 7.


Figura 7 - Representação de uma rede neural que possui diversas entradas num neurônio artificial.



Fonte: Adaptado de Finochio (2014).

Se neurônios são adicionados a cada camada, conseqüentemente aumenta-se a “inteligência” da rede neural, pois serão várias funções de ativação e vários parâmetros a serem estimados. Na Figura 8 apresenta-se um diagrama esquemático de uma rede neural artificial com diversas camadas.

Figura 8 - Representação de uma rede neural com diversas camadas de neurônios artificiais interligados. Os estímulos são as entradas dos neurônios.



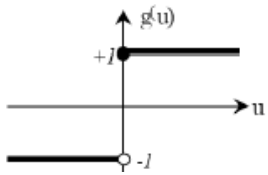
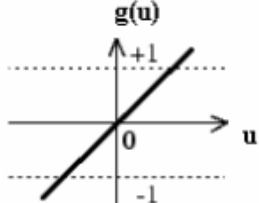
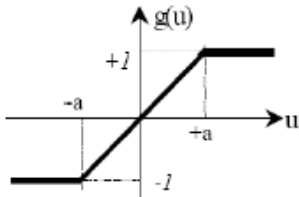

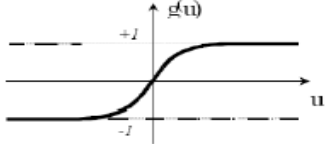
Fonte: Adaptado de Finochio (2014).

Entretanto, processos industriais envolvem informações numéricas (temperatura, pressão, frações molares, etc) e subjetivas (bom, ruim, mais ou menos, etc). Então, é necessário criar uma escala para que as informações subjetivas possam ser quantificadas numericamente. Já as informações numéricas, quantitativas, devem possuir uma mesma escala. Caso contrário, um ajuste considerado excelente para o conjunto de temperaturas, que apresente apenas 0,5 K de desvio, trata-se de um erro elevado quando avalia-se frações molares. Assim, percebe-se que o desafio para a implementação de RNAs consiste em se tratar adequadamente a informação antes de processá-la.

O primeiro passo relacionado ao tratamento de dados consiste em definir o tipo de função de ativação a ser utilizada. As mais comuns estão descritas no Quadro 2.

Quadro 2 - Tipos de função de ativação

Tipo de função de ativação	Gráfico da função de ativação	Extremos da função de ativação
1. Degrau assimétrica ou <i>hard limit</i>		$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (2)$

2. Degrau simétrica		$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ -1 & \text{se } u < 0 \end{cases} \quad (3)$
3. Linear		$g(u) = u \quad (4)$
4. Linear tipo rampa		$g(u) = \begin{cases} 1 & \text{se } u \geq a \\ u & \text{se } -a < u < a \\ -1 & \text{se } u \leq -a \end{cases} \quad (5)$
5. Sigmóide logarítmica		$g(u) = \frac{1}{1 + e^{(-\beta u)}} \quad (6)$
6. Sigmóide tangencial		$g(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}} \quad (7)$

Fonte: O autor (2023).

Pela sua versatilidade e possuir características não-lineares (o que possibilita a representação de dados extremamente complexos) a função de ativação tipo sigmóide tangencial é preferencialmente utilizada. Principalmente quando se dispõe de sistemas esparsos. No processamento têxtil, encontra-se ambas as situações: sistemas não lineares e esparsos. Logo, a função de ativação sigmóide tangencial passa a ser a primeira opção a ser empregada.

Após a definição da função de ativação, é necessário escalonar os dados para os limites da função que são -1 e +1. Estudos prévios têm demonstrado que não se deve saturar a saída da função de ativação. Em outras palavras, não deve-se trabalhar nos limites inferior e superior. Por exemplo, Haykin (1999) recomenda, no caso da função de ativação do tipo sigmóide tangencial, que o escalonamento seja realizado

entre -0,8 e + 0,8, conforme as Equações 2 e 3, para os dados de entrada e saída, respectivamente.

$$P = -0,8 + 1,6 \cdot \left[\frac{P - x_{min}}{x_{max} - x_{min}} \right] \quad (2)$$

$$T = -0,8 + 1,6 \cdot \left[\frac{T - y_{min}}{y_{max} - y_{min}} \right] \quad (3)$$

Onde:

P = conjunto de dados de entrada

T = conjunto dos dados de saída

x_{min} = menor valor dos elementos do conjunto P dos dados de entrada

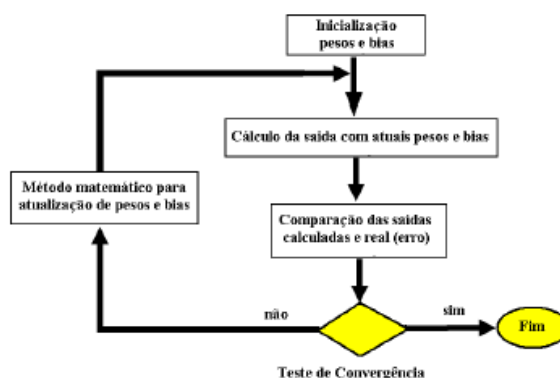
x_{max} = maior valor dos elementos do conjunto P dos dados de entrada

y_{min} = menor valor dos elementos do conjunto T dos dados de saída

y_{max} = maior valor dos elementos do conjunto T dos dados de saída

Por fim, em termos de treinamento, vários algoritmos de otimização podem ser utilizados, sendo alguns mais rápidos, outros mais lentos. O mais comum é o uso de algoritmos do tipo passo descendente. Nasra et al. (2016) exploraram diferentes algoritmos de treinamento, concluindo que o método de Levenberg–Marquardt possui uma velocidade maior de convergência, motivo pelo qual será utilizado neste trabalho. Outros algoritmos de otimização podem ser encontrados em Yin et al. (2003). Na Figura 9 pode-se observar o fluxograma da fase de treinamento (*machine learning*).

Figura 9 - Fase de treinamento da rede neural



Fonte: Adaptado de Finochio (2014).

No próximo subitem será apresentado alguns trabalhos de inteligência artificial no beneficiamento têxtil.

2.3.2 Inteligência artificial e o beneficiamento têxtil

A aplicação da IA no setor do têxtil representa uma evolução no cenário da indústria moderna. A integração de algoritmos inteligentes, aprendizado de máquina e automação tem revolucionado os processos desde a concepção do design até a produção final. Na Tabela 1 apresenta-se uma síntese geral das contribuições de RNAs para a indústria têxtil. Destaca-se que de acordo com Sikka e colaboradores (2022), operações de teste e controle de qualidade na forma de processamento de imagens são as áreas com maior aplicação de redes neurais atualmente na indústria têxtil.

Tabela 1 - Síntese de trabalhos desenvolvidos com RNA e a indústria têxtil.

Autores	Objetivo do trabalho
Bahlmann et al. (1999)	Desenvolver RNA para estabelecer um controle automatizado em costuras têxteis.
Hui et al. (2007)	Desenvolver RNA para desempenho de costuras têxteis.
Elemen et al. (2012)	Estimar o processo de adsorção de corantes em argilas sob diferentes condições.
Furferi et al. (2012)	Prever as características finais de um tecido revestido, com base nos parâmetros do processo.
Azim (2015)	Identificar defeitos em têxteis, permitindo controle de qualidade on-line
Tiwari et al. (2023)	Aplicação de RNA para avaliar o desempenho de tecidos produzidos.
Doran et al. (2019)	Desenvolver RNA para predição de fios de algodão e elastano.
Jeyaraj et al. (2019)	Utilização de RNA para detecção de defeitos no processo de fabricação de tecidos
Li et al. (2021)	Identificação de resíduos gerados pela indústria têxtil utilizando RNA

Fonte: O autor, (2023).

A fusão entre IA e beneficiamento têxtil oferece oportunidades para otimizar a eficiência, a precisão e a sustentabilidade em todas as fases do processo, incluindo estamparia, tingimento, acabamento e controle de qualidade. Essa convergência inovadora está remodelando não apenas a maneira como os tecidos são produzidos,

mas também está redefinindo os padrões de qualidade, personalização a velocidade de resposta às demandas do mercado (Sikka et al., 2022; Chattopadhyay; Guha,2004).

Especificamente no caso da RNAs, avanços foram identificados no campo do beneficiamento têxtil. Atualmente, essas redes são aplicadas no controle de qualidade de tecidos, permitindo a identificação de defeitos, padrões de tingimento e falhas no acabamento de forma muito mais precisa e eficiente do que os métodos convencionais. Além disso, as RNAs têm sido utilizadas na otimização dos parâmetros dos processos, tais como temperatura, tempo de tingimento e composição de produtos químicos. Ademais, modelos baseados em RNA desempenham um papel crucial na previsão das propriedades finais dos tecidos, incluindo resistência, durabilidade e comportamento frente ao encolhimento. Isso possibilita ajustes precisos nos processos de fabricação, contribuindo para aprimorar a qualidade dos produtos têxteis (Sikka et al., 2022).

Entre os estudos mais recentes envolvendo redes neurais na etapa de beneficiamento, especificamente tingimento, cita-se:

- i. A avaliação do tingimento de polyester e o uso de redes neurais em conjunto com algoritmos genéticos para predizer os valores K/S (Haji; Vadood, 2021);
- ii. Otimização das condições operacionais de tingimento com corante reativo combinando-se técnicas de ANNs, metodologia de superfície de resposta e *particle swarm* (Rosa et al., 2021);
- iii. A predição das coordenadas colorimétricas de tecidos celulósicos em tingimento com corantes naturais (Vadood; Haji, 2022);
- iv. Predição dos valores CIELab (L^* , a^* e b^*) de fios tingidos a partir das propriedades da fibra de algodão, parâmetros do processo de fiação, tingimento e acabamento como conjuntos de entrada da rede neural (Şahin et al., 2023).
- v. Otimização do processo de tingimento com corante indigo combinando redes neurais e análise de superfície de resposta (Abdelileh et al., 2023);
- vi. Estimativa das propriedades de tingimento de lã tratada com plasma e tingido com corante natural (Basyigit et al., 2023);

- vii. Análise do grau de exaustão do tingimento de algodão por meio de um modelo de predição baseado em perceptron multicamadas (Jeong et al., 2023);
- viii. Estimativa das propriedades de tingimento de tecidos de lã, K/S, mudança de cor, resistência à fricção seco e úmido (Eyupoglu et al., 2024);

Analisando o cenário apresentado e as aplicações das RNAs, conclui-se que existem muitas oportunidades a serem exploradas. Neste trabalho, explorou-se, de forma pioneira, a questão do tingimento da poliamida. Embora nem todos os processos envolvidos sejam conhecidos a fundo, a abordagem utilizada é uma avaliação da viabilidade de se explorar a aplicação de redes neurais artificiais para incrementar os processos de tingimento e reduzir o volume de retrabalho. Posteriormente, a pretensão é empregar uma estratégia semelhante, integrada a rede industrial de dados da empresa, para prever possíveis falhas de tingimento e aplicar as correções necessárias. Além da redução do retrabalho, avalia-se que os insumos serão empregados de forma mais eficiente e o custo de produção será impactado de forma bastante significativa. Desta forma, o trabalho aqui iniciado é pioneiro e indica novos rumos a serem tomados e analisa a viabilidade de se usar a inteligência artificial de forma mais massiva na indústria têxtil.

Apesar dos avanços, alguns desafios persistem, como a necessidade de conjuntos de dados mais robustos e representativos, além da interpretabilidade dos modelos para aplicação industrial. Além disso, o potencial das redes neurais em simular processos complexos ainda está em evolução (Sikka et al., 2022).

3 MATERIAIS E MÉTODOS

Essa pesquisa foi desenvolvida em parceria com uma empresa têxtil localizada em Indaial/SC, e é composta por diferentes etapas atreladas com a coleta e preparação de dados, desenvolvimento da RNA, bem como o treinamento e validação da RNA desenvolvida. Uma vez que o desenvolvimento da rede é o foco deste trabalho, as definições normalmente descritas neste Capítulo serão apresentadas e discutidas no Capítulo 4, de Resultados e Discussão.

3.1 DEFINIÇÃO DO PROBLEMA

O parque fabril da empresa em questão é composto por malharia, tinturaria e acabamento, porém a pesquisa foi realizada no setor de tinturaria devido ao percentual de reprocesso. Os tingimentos de poliamida serão a base de estudo, devido à sua importância e por corresponder a maior parcela da produção, porém é importante mencionar que a empresa também realiza tingimentos de poliéster e viscose.

A empresa possui um amplo portfólio de produtos, com diversos artigos diferentes de poliamida, cada um disponível em uma variedade de cores distintas. Cada um desses artigos apresenta variações no fornecedor do fio utilizado, além disso, as malhas de poliamida estudadas possuem composições de tecido que combinam poliamida com elastano, um elastômero sintético conhecido por sua capacidade de esticar e recuperar sua forma original.

Adicionalmente, outras variáveis significativas abrangem os parâmetros de processamento, como o tipo de máquina empregada, a qualidade da água e o uso de corantes e produtos químicos auxiliares, juntamente com diversos gráficos de tingimento. Esses gráficos são representações visuais que descrevem o comportamento do processo de tingimento ao longo do tempo. Eles são utilizados para monitorar e controlar as condições do processo, tais como temperatura, pressão e tempo de tingimento.

Considerando a complexidade e quantidade das variáveis envolvidas no processo, é possível que a malha não atinja a qualidade desejada, exigindo procedimentos de reprocessamento. Abaixo estão as situações que requerem o reprocesso da malha na tinturaria:

3.1.1 Barramento

O barramento refere-se a faixas ou listras visíveis na malha após o tingimento conforme Figura 10.

Figura 10 - Malha com defeito de barramento



Fonte: O autor (2023).

3.1.2 Manchas e Má Igualização

Manchas são áreas da malha que apresentam coloração irregular ou desbotada, em comparação com o restante do tecido, conforme mostrado na Figura 11. Elas podem ocorrer em áreas isoladas ou em uma quantidade maior da malha, no caso de má igualização.

Figura 11 - Malha com defeito de manchas



Fonte: O autor (2023).

3.1.3 Quebras

As quebras são áreas onde a cor não é uniforme e pode haver interrupções abruptas na tonalidade conforme Figura 12.

Figura 12 - Malha com defeito de quebras



Fonte: O autor (2023).

3.1.4 Tonalidade

A tonalidade refere-se à uniformidade da cor em toda a extensão da malha ou cor obtida diferente do padrão. A Figura 13 apresenta a diferença de tonalidade entre duas malhas provenientes de processos diferentes.

Figura 13 - Malha com defeito de tonalidade



Fonte: O autor (2023).

3.2 COLETA E PREPARAÇÃO DOS DADOS

Durante o período de julho a outubro de 2023 foi realizado um levantamento dos dados de entrada do tingimento de forma a definir quais seriam utilizados na rede. Os critérios de seleção dos dados incluíram a avaliação do impacto do resultado na qualidade do tingimento, assim como a disponibilidade de automação dos dados na empresa. Tais definições e discussões são apresentadas no Capítulo 4.

Foi realizado o levantamento da produção de apenas uma máquina (conforme discutido no Capítulo seguinte - da máquina 40) entre os dias 01/11/23 a 29/02/24 por meio do acompanhamento dos processos e levantamento de dados junto ao sistema operacional da empresa (Apêndice A). As 196 amostras foram divididas na seguinte proporção: 80% para treinamento, 10% para validação cruzada e 10% para teste, conforme será descrito no próximo Capítulo.

De acordo com os conjuntos de dados obtidos foi proposta uma arquitetura inicial para a RNA, a qual foi treinada até que possa representar os dados reais com relativa precisão. Após a fase de treinamento, a rede foi validada com um novo conjunto de dados (etapa chamada de validação cruzada) visando prever possíveis desvios na qualidade do produto acabado e, conseqüente reprocesso.

3.3 DESENVOLVIMENTO DA ARQUITETURA DA REDE NEURAL ARTIFICIAL

Foi necessário definir a arquitetura da rede, determinando o número de camadas, neurônios em cada camada e a função de ativação adequada. Embora existam algumas abordagens na literatura para projetar a arquitetura de uma rede neural, procurou-se utilizar uma abordagem simples devido à complexidade do conjunto de dados.

Logo, a rede foi projetada por tentativa e erro e com o emprego do algoritmo de análise do componente principal, conforme a seguinte topologia:

3.3.1 Camada de Entrada

Possui 10 neurônios na camada de entrada, correspondendo aos 10 atributos de entrada do conjunto de dados conforme descrito no Capítulo 4.

3.3.2 Camada Oculta

Possui uma camada oculta com um número não especificado de neurônios. O número de neurônios na camada oculta é especificado pelo comando `feedforwardnet(10)`, onde 10 é o número de neurônios na camada de entrada.

3.3.3 Camada de Saída

Consiste em um único neurônio, representando a saída desejada, a qual foi definida como 'Liberado' ou 'Reprocesso'.

3.3.4 Funções de Ativação

No processamento têxtil, encontramos ambas as situações, sistemas não lineares e esparsos. Logo, a função de ativação sigmóide tangencial será empregada.

3.3.5 Tipo de Rede

A rede neural é do tipo feedforward, o que significa que as informações fluem em uma única direção, da camada de entrada para a camada de saída, sem ciclos ou retroalimentação.

3.3.6 Algoritmo de Aprendizagem

O algoritmo de aprendizagem utilizado é Levenberg-Marquardt. Este é um algoritmo de otimização eficiente para problemas de regressão que ajusta os pesos da rede de acordo com o gradiente descendente, mas com uma modificação para acelerar a convergência, especialmente em torno de mínimos locais.

O software empregado foi o MATLAB, devido a UFSC possui licença do mesmo. O MATLAB é um ambiente de programação para desenvolvimento de algoritmos, análise de dados, cálculo numérico e visualização de gráficos. O ambiente tem várias aplicações integradas, o que o torna resolver problemas de computação técnica com maior rapidez do que outras linguagens. Redes neurais podem ser implementadas no MATLAB com apenas algumas linhas de código e funções disponíveis no software.

3.4 TREINAMENTO E VALIDAÇÃO DA REDE NEURAL ARTIFICIAL

No processo de ajuste de treinamento e validação da rede neural, todos os procedimentos foram realizados de forma automatizada pelo MATLAB, utilizando as ferramentas e funções disponíveis no programa conforme descrito no Capítulo 4.

Após a execução do script com as funções de treinamento, teste e validação, o programa realiza a avaliação dos resultados. Os pesos e os *bias* foram avaliados pela técnica de análise do componente principal (PCA), a qual é usada para simplificar a complexidade dos dados, identificando e destacando padrões e estruturas subjacentes nos mesmos. Os neurônios cujos pesos e *bias* são considerados valores desprezíveis foram excluídos da arquitetura da rede, e na sequência a mesma foi retreinada. O procedimento foi repetido até que se obteve a reprodução do resultado com base em métricas de avaliação de desempenho, como o erro médio quadrático. A partir deste momento, o número de camadas e de neurônios suficientes para que a rede represente o processo adequadamente foi definido.

Neste documento são discutidos os resultados obtidos apenas com a rede final, já com o número de camadas e neurônios definidos, pois o objetivo não é demonstrar como se cria a estrutura de uma rede neural, mas sim explorar sua aplicabilidade em indústrias têxteis.

3.5 IMPLEMENTAÇÃO EM AMBIENTE DE PRODUÇÃO

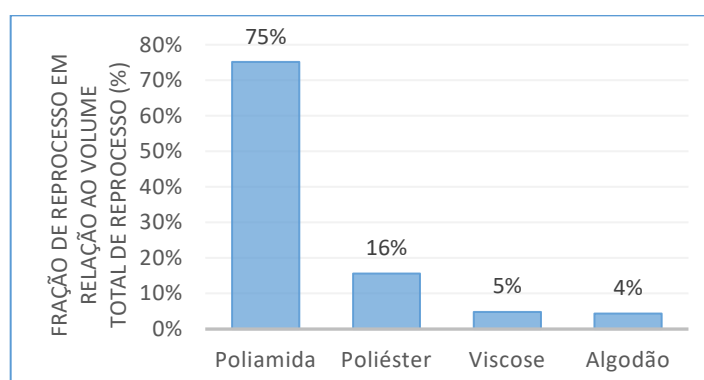
Após a validação do desempenho da rede, a mesma foi testada no ambiente de produção visando uma demonstração do seu funcionamento em planta. Foram avaliados em tempo real 10 novos lotes que estavam na etapa de tingimento. Os dados de entrada desses novos lotes foram inseridos no MATLAB, e o valor de saída da rede foi acompanhado para verificar sua correspondência com o resultado real.

4 RESULTADOS E DISCUSSÃO

4.1 RELEVÂNCIA DO PROBLEMA

Conforme Figura 14, pode-se observar que as malhas de fibras de poliamida e poliéster representam o maior volume de reprocesso, sendo este valor na ordem de 75% e 16% do total reprocessado. Em linhas gerais, as taxas de reprocessamento observadas podem ser atribuídas às complexidades inerentes aos processos de produção e às propriedades intrínsecas desses materiais. A poliamida, conhecida por sua resistência, pode enfrentar desafios durante a produção devido à sua natureza. Adicionalmente, a sensibilidade desses materiais a variações nas condições de processamento também contribui para essas taxas elevadas de reprocessamento. A empresa fabrica poliamida 6 e 6.6; no entanto, neste estudo, essa variável não foi levada em consideração.

Figura 14 - Fração de reprocesso em relação ao volume total de reprocesso (%)



Fonte: O autor (2023).

Especificamente para a fibra de poliamida, na Tabela 2 apresenta-se as causas dos reprocessos gerados. Destaca-se que cerca de 95% dessas ocorrências são classificadas como indefinidas pela empresa, indicando uma falta de clareza sobre suas causas específicas, o que compromete a possibilidade de se identificar e solucionar tais problemas. Essa falta de precisão na identificação das causas impede uma intervenção direcionada e efetiva para resolver as questões relacionadas ao reprocessamento da poliamida.

O elevado índice de ocorrências indefinidas de reprocessamento na fibra de poliamida pode derivar de múltiplos fatores. A complexidade dos processos de

produção dessa fibra, que envolvem etapas químicas e mecânicas delicadas, pode propiciar uma gama extensa de possíveis falhas, desde variações na composição química até inadequações na temperatura ou pressão durante o processo. Além disso, a dificuldade de monitorar todas as variáveis envolvidas pode contribuir para a imprecisão na identificação das causas, criando lacunas na compreensão dos eventos que levam ao reprocessamento. Essa falta de clareza pode ser agravada pela ausência de sistemas robustos de rastreamento ou de métodos de registro detalhados, dificultando a atribuição precisa das causas dos problemas de qualidade, resultando, assim, nessa alta porcentagem de ocorrências indefinidas.

Tabela 2 - Causas dos reprocessos gerados na produção de poliamida

Causas	Reprocesso (%)
Total geral	-
Indefinida	95
Falha operacional	1
Teste área técnica	1
Receita errada	1
Matéria prima	1
Problema elétrico	0
Problema mecânico	0
Matéria prima- fio	0
Concentração errada	0
Teste processo novo	0

Fonte: O autor (2023).

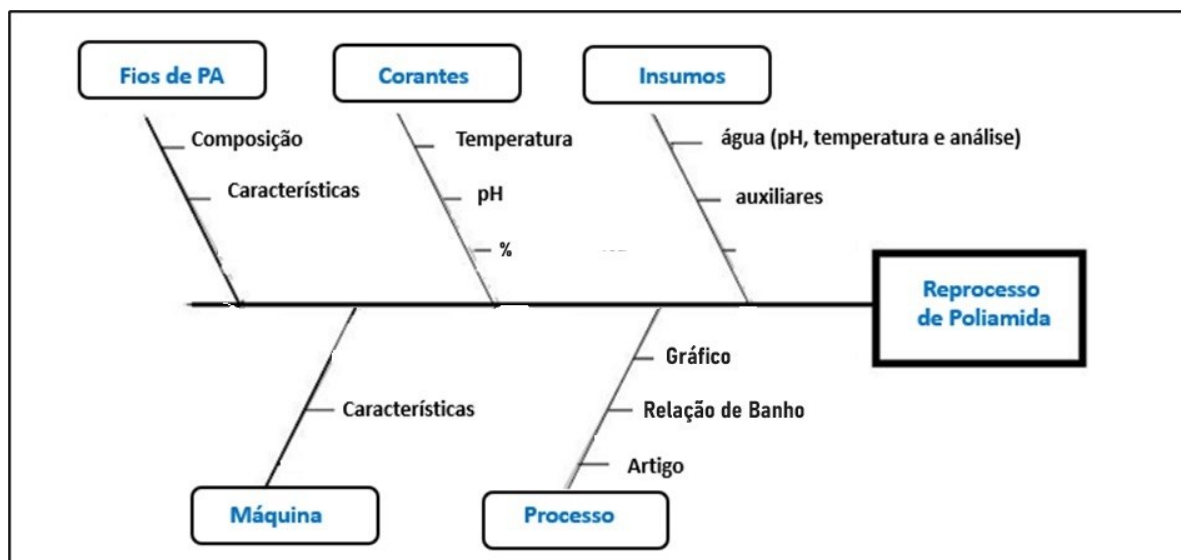
A prática adotada na empresa consiste em que os produtos que não podem ser reprocessados devido às variações de cor, são tingidos na cor preta. Neste caso, além dos corantes serem perdidos, ainda existe a necessidade de refazer todo o processo para a obtenção do produto na cor preta (e que ainda pode estar sujeito a falhas), implicando em custos maiores de matéria-prima e energia para este tingimento.

4.2 AVALIAÇÃO DAS VARIÁVEIS DO PROCESSO PARA DEFINIÇÃO DOS DADOS DE ENTRADA DA RNA.

Foi realizado um levantamento das variáveis que influenciam no reprocesso e avaliado quais dos dados estariam disponíveis para a implementação na rede neural.

Na Figura 15 apresenta-se um esquema demonstrando as variáveis identificadas como possíveis entradas da RNA.

Figura 15 - Variáveis identificadas para a entrada da RNA.



Fonte: O autor (2024).

4.2.1.1 Fios de poliamida e elastano

O fio de poliamida, juntamente com o elastano, desempenha um papel fundamental na produção de malhas têxteis, oferecendo uma ampla gama de propriedades que influenciam diretamente na qualidade do tecido final. O elastano apresenta desafios significativos no tingimento de poliamida devido à sua baixa afinidade por corantes, resultando em absorção irregular ou reduzida de corante em comparação com a poliamida. Isso pode causar variações na intensidade e na uniformidade da cor ao longo do tecido, especialmente em áreas com maior concentração de elastano. Além disso, suas características de absorção de umidade influenciam a fixação dos corantes durante o processo de tingimento, exigindo ajustes precisos nas formulações de banho e nos tempos de processo para otimizar a penetração e a fixação dos corantes em tecidos mistos de poliamida e elastano.

Nesse sentido, sabe-se que cada fio possui uma característica própria. Para treinar a rede utilizou-se os diferentes tipos de fornecedores. Devido ao segredo industrial, chamaremos de: Fornecedor 1, Fornecedor 2, Fornecedor 3 e Fornecedor 4 para poliamida e Fornecedor 5, Fornecedor 6, Fornecedor 7, Fornecedor 8 e Fornecedor 9 para elastano.

A composição do fio se refere a porcentagem utilizada em cada artigo. Essa composição também foi considerada para as entradas da rede, pois cada artigo estudado possui uma composição diferente de poliamida e elastano.

4.2.1.2 *Corantes*

O corante utilizado desempenha um papel fundamental no processo de tingimento, e fatores como temperatura, pH e características específicas do corante influenciam na qualidade do tingimento.

O pH da solução de tingimento é um fator crítico a ser considerado. O pH influencia a solubilidade e a estabilidade do corante, bem como sua afinidade pelas fibras de poliamida. Desvios elevados no pH podem resultar em problemas como mudanças na tonalidade da cor, deposição irregular do corante ou mesmo danos às fibras. Portanto, é essencial ajustar e controlar o pH da solução de tingimento para garantir resultados consistentes e de alta qualidade. No entanto, o histórico de pH dentro do processo de tingimento da empresa não é automatizado, o que inviabilizou o uso desse parâmetro como entrada da rede neural. Diante disso, sugere-se como primeiro resultado desta análise que a empresa automatize a leitura de pH visando a implementação de um sistema completo de monitoramento e controle. Como isso requer investimento, parada de fábrica e reinício de todos os processos, não houve tempo hábil para que se automatizasse a leitura desta variável. Entretanto, ficou bastante claro que a empresa, caso queira melhorar seus processos, precisará fazer o investimento mencionado.

Em relação a classe do corante, utilizou-se apenas os corantes ácidos, característicos para o tingimento de poliamida. Assim, essa variável também não foi definida como uma entrada para a rede.

A concentração de corante utilizada afeta diretamente a intensidade da cor no tecido tingido. Quanto maior a porcentagem de corante, mais intensa será a cor obtida. Portanto, é importante determinar a quantidade correta de corante com base na tonalidade desejada para o produto final. Por esta razão, a porcentagem total do corante utilizado foi definida como uma das entradas da rede neural.

4.2.1.3 *Banho e Insumos*

Os auxiliares têxteis são produtos químicos adicionados ao banho de tingimento para melhorar e otimizar o processo e, semelhante ao que ocorre com o corante, a composição é considerada um segredo industrial. Estes auxiliares desempenham uma variedade de funções, incluindo a melhoria da solubilidade do corante, o aumento da afinidade entre o corante e a fibra, a prevenção de manchas e o controle da dispersão do corante. A formulação/ composição do banho de tingimento é uma entrada da rede e por meio desta é possível verificar todos os auxiliares utilizados. Na empresa, essa formulação é chamada de receita.

Ao realizar o tingimento têxtil, a qualidade da água é de extrema importância, pois pode afetar significativamente o processo e o resultado final. Alguns dos parâmetros da água avaliados na empresa são: pH, turbidez, alumínio, ferro, dureza e condutividade. O histórico das análises da água dentro do processo de tingimento da empresa também não é automatizado, o que inviabilizou o uso desses parâmetros como entrada da rede neural. Porém, tais informações poderão ser inseridas posteriormente, no caso de uma implementação industrial.

4.2.1.4 *Máquina*

A definição do tipo de máquina de tingimento adequada e a realização de manutenção regular são fundamentais para garantir resultados de tingimento consistentes e de alta qualidade na indústria têxtil.

Na malharia existem diversos teares e o número do tear utilizado foi definido como uma das entradas da rede neural. Embora o tear não esteja diretamente relacionado ao processo de tingimento, pode haver uma correlação indireta entre o número de tear e algumas características do tingimento. Por exemplo, determinadas configurações de tear podem influenciar indiretamente as condições de tingimento, como a velocidade ou a tensão do tecido, que por sua vez afetam o resultado final do tingimento.

Devido à complexidade dos tipos de máquina de tingimento foi definido trabalhar apenas com uma máquina de tingir. Essa decisão foi tomada para simplificar a análise dos dados, uma vez que a variedade de modelos e fabricantes poderia dificultar a interpretação dos resultados. Como este trabalho é o primeiro do gênero a ser

desenvolvido, limitou-se o estudo para avaliar sua potencialidade, não incluindo muitas variáveis de forma a dificultar a interpretação dos resultados.

A escolha da máquina foi realizada pela empresa, considerando os dados históricos de produção. Ao analisar os registros, constatou-se que a Máquina 40 se destacava por lidar principalmente com poliamida e apresentar maior índice de reprocesso. A máquina HT40 possui capacidade nominal de 600kg e é dotada de cestos horizontais. Este equipamento opera no formato de batelada, o que significa que cada ciclo de tingimento processa uma quantidade específica de material.

4.2.1.5 *Processo*

Durante o processo a malha é gradualmente aquecida até a temperatura ideal para a aplicação do corante e auxiliares. A curva de aquecimento é controlada e registrada como parte do gráfico de tingimento, sendo que esse gráfico pode variar conforme o artigo/cor.

A temperatura do banho de tingimento desempenha um papel importante na eficácia do processo. A temperatura adequada pode melhorar a solubilidade do corante, acelerar a taxa de difusão do mesmo nas fibras e melhorar a fixação da cor ao tecido. Na rede neural, foi empregado o número do gráfico utilizado como entrada da rede neural, nesse está incluso o tempo e temperatura utilizada. Por questões de segredo industrial não foi apresentado maiores detalhes dos gráficos de tingimento.

A relação de banho é um conceito importante no processo de tingimento têxtil, referindo-se à proporção entre a quantidade de tecido e a quantidade de líquido de tingimento (banho) presente na máquina de tingimento. Essa relação desempenha um papel crucial na determinação da qualidade e eficiência do tingimento. Desde modo a Relação de Banho foi definida uma das entradas da rede neural.

4.2.2 Definição dos Dados de Entrada e Saída

Os dados de entrada representam as características ou variáveis independentes, enquanto os dados de saída representam as respostas ou variáveis dependentes que se deseja prever. Definido 10 entradas para a rede (Receita, Artigo, Tear, %PA, %PUE, Fornecedor Fio, Fornecedor Elastano, Gráfico, %Corante e Relação de banho) e uma saída (Liberado ou Reprocesso).

Os dados qualitativos das entradas referentes ao Fornecedor de Fio e Elastano foram transformados em valores numéricos para serem compatíveis com a inserção na rede neural no MATLAB, conforme Tabela 3. No caso dos dados de saída, em que a qualidade foi indicada como 'liberado', foi atribuído o código 13, enquanto para o status de 'reprocesso', o código 14 foi utilizado. Em contrapartida, os dados de entrada numéricos (Receita, Artigo, Tear, %PA, %PUE, Gráfico, %Corante e Relação de banho) não requereram nenhum tratamento adicional para serem incorporados à rede.

Tabela 3 - Dados utilizados para a conversão numérica

Fornecedor fio	Código	Fornecedor Elastano	Código
Fornecedor 1	1	Fornecedor 5	8
Fornecedor 2	2	Fornecedor 6	9
Fornecedor 3	3	Fornecedor 7	10
Fornecedor 4	4	Fornecedor 8	11
		Fornecedor 9	12

Fonte: O autor (2024).

Após definir os dados de entrada/saída e ajustar para conversão numérica obtém-se os dados identificados no Apêndice B.

4.3 CONSTRUÇÃO DA REDE NEURAL NO MATLAB

Para construção de uma RNA no MATLAB são necessários os seguintes passos:

1. Definir os padrões de entrada e saída (já descrito anteriormente);
2. Inicializar da rede;
3. Treinar a rede
4. Executar a rede

Os dados foram armazenados em um arquivo, e foi utilizada a função *xlsread* para carregá-los no MATLAB. Nessa etapa foi importante se certificar que os dados estavam formatados corretamente e que não havia valores ausentes ou corrompidos. Posteriormente foi ajustado o nome do arquivo, nome da planilha, intervalo de colunas conforme apresentado na Figura 16.

Figura 16 - Programação utilizada para armazenamento dos dados.

```
>> % Carregar dados do arquivo Excel
arquivo = 'C:\Users\franc\Downloads\Dados nov a fev filtrados.xlsx';
planilha = 'Filtrados';
dados = xlsread(arquivo, planilha, 'A:K'); % Lendo todas as colunas de A a K

% Separar dados de entrada e saída
dadosEntrada = dados(:, 1:10); % Colunas 1 a 10 são dados de entrada
dadosSaidaDesejada = dados(:, 11); % Coluna 11 é a saída desejada

% Número de amostras
numAmostras = size(dados, 1);
```

Fonte: O autor (2024).

4.3.1 Definição dos dados de treinamento e teste

Devido ao número de dados, foi possível dividir em conjuntos de treinamento, validação cruzada e teste. Isso foi importante para avaliar o desempenho da rede neural em dados não empregados na fase de treinamento. O conjunto de treinamento é usado para treinar a rede, enquanto o conjunto de teste é usado para avaliar o desempenho da rede. Normalmente, utiliza-se uma proporção maior para treinamento, seguida por uma proporção menor para validação cruzada e teste.

As 196 amostras foram divididas na seguinte proporção: 80% para treinamento, 10% para validação cruzada e 10% para teste. Os comandos utilizados são apresentados na Figura 17.

Figura 17 - Programação utilizada para divisão dos conjuntos de dados.

```
% Dividir os dados em conjuntos de treinamento, validação cruzada e teste
percentualTreinamento = 0.8;
percentualValidacao = 0.1;
percentualTeste = 0.1;

% Número de amostras para treinamento
numTreinamento = round(percentualTreinamento * numAmostras);
dadosTreinamentoEntrada = dadosEntrada(1:numTreinamento, :);
dadosTreinamentoSaidaDesejada = dadosSaidaDesejada(1:numTreinamento, :);

% Número de amostras para validação cruzada
numValidacao = round(percentualValidacao * numAmostras);
dadosValidacaoEntrada = dadosEntrada(numTreinamento+1:numTreinamento+numValidacao, :);
dadosValidacaoSaidaDesejada = dadosSaidaDesejada(numTreinamento+1:numTreinamento+numValidacao, :);

% Número de amostras para teste
numTeste = numAmostras - numTreinamento - numValidacao;
dadosTesteEntrada = dadosEntrada(numTreinamento+numValidacao+1:end, :);
dadosTesteSaidaDesejada = dadosSaidaDesejada(numTreinamento+numValidacao+1:end, :);
```

Fonte: O autor (2024).

4.4 CRIAÇÃO DA REDE NEURAL E DEFINIÇÃO DA ARQUITETURA INICIAL

As redes neurais *feedforward* processam dados em uma direção, do nó de entrada para o nó de saída. Cada nó de uma camada está conectado a todos os nós da próxima camada. Foi utilizado a função *feedforwardnet* para criar a rede neural feedforward, e foi especificado o número de neurônios na camada oculta como 10 e adicionado as características desejadas, como funções de ativação e algoritmos de treinamento. Os comandos utilizados são apresentados na Figura 18.

Figura 18 - Programação utilizada para a criação da rede neural.

```
% Criar uma rede neural feedforward
redeNeural = feedforwardnet(10); % 10 neurônios na camada oculta

% Configurar as características da rede
redeNeural.layers{1}.transferFcn = 'logsig'; % Função de ativação da camada oculta (logsig =
redeNeural.layers{2}.transferFcn = 'purelin'; % Função de ativação da camada de saída (purel
redeNeural.trainFcn = 'trainlm'; % Treinamento com o algoritmo de Levenberg-Marquardt
redeNeural.divideFcn = ''; % Não dividir os dados em conjuntos de treinamento, validação e t
```

Fonte: O autor (2024).

4.4.1 Treinamento da Rede Neural

Utilizou-se a função *train* para treinar a rede neural com os dados de treinamento, especificado os dados de entrada e saída desejados, conforme ilustrado na Figura 19.

Figura 19 - Comandos utilizados para o treinamento da rede neural.

```
% Treinar a rede neural
redeNeural = train(redeNeural, dadosTreinamentoValidacaoEntrada', dadosTreinamentoValidacao!
```

Fonte: O autor (2024).

4.4.2 Validação Cruzada e Ajuste de Parâmetros da arquitetura da rede

Utilizou-se os dados de validação cruzada para ajustar os parâmetros da rede neural, como o número de neurônios na camada oculta, taxa de aprendizado, entre outros. O objetivo principal da validação cruzada foi estimar a capacidade de

generalização do modelo para dados não utilizados durante o treinamento e melhorar o desempenho do modelo. Os comandos descritos são apresentados na Figura 20.

Figura 20 - Comandos utilizados para a validação da rede neural.

```
% Combinar dados de treinamento e validação cruzada
dadosTreinamentoValidacaoEntrada = [dadosTreinamentoEntrada; dadosValidacaoEntrada];
dadosTreinamentoValidacaoSaidaDesejada = [dadosTreinamentoSaidaDesejada; dadosValidacaoSaidaDesejada];
```

Fonte: O autor (2024).

4.4.3 Teste da Rede neural artificial

Após o treinamento, foi realizado o teste da rede neural, usando os dados de teste. Utilizado a função `sim` para obter as previsões da rede neural para os dados de teste (Figura 21).

Figura 21 - Comandos utilizados para o teste da rede neural.

```
% Testar a rede neural com os dados de teste
saidaRede = sim(redeNeural, dadosTesteEntrada');
```

Fonte: O autor (2024).

4.4.4 Avaliação e ajuste da Rede neural artificial

Foi avaliado o desempenho da rede neural e realizado ajustes conforme necessários. Isso pode envolver a modificação de hiper parâmetros da rede, como o número de neurônios na camada oculta ou a taxa de aprendizado, ou a coleta de mais dados se o desempenho da rede for insatisfatório. Na Figura 22 apresenta-se a tela do programa MATLAB e o script utilizado.

Figura 22 - Comandos utilizados para avaliar a rede neural

```
% Avaliar o desempenho da rede (por exemplo, erro médio quadrático)
erroMedioQuadratico = immse(saidaRede, dadosTesteSaidaDesejada);
disp(['Erro Médio Quadrático da rede neural: ', num2str(erroMedioQuadratico)]);
```

Fonte: O autor (2024).

O erro médio quadrático (EMQ) é uma medida do quanto os valores previstos pela rede neural se desviam dos valores reais. Quanto menor o valor do EMQ, melhor

o desempenho da rede, pois isso indica que a rede está produzindo saídas mais próximas dos valores reais.

4.5 DESEMPENHO DA REDE NEURAL TREINADA.

A arquitetura da rede neural definida consiste em uma camada com 10 valores de entrada, uma camada oculta também com 10 valores e uma camada com uma saída. Cada camada está conectada por pesos (W) e bias (b). Não foi necessário ajustar a arquitetura da rede proposta inicialmente, pois ela demonstrou bons valores de desempenho durante o treinamento e teste.


O desempenho do treinamento da rede foi avaliado pelos parâmetros indicados pelo próprio MATLAB:

- a. A Época (Epoch) indica o número de vezes que o conjunto de dados de treinamento completo foi processado, ou seja, 1000 vezes.
- b. O erro de desempenho final foi 0,0031, o que é um valor bastante baixo e indicativo de um bom ajuste.
- c. O valor do gradiente foi de 0,953, considerado baixo e sugerindo que o treinamento convergiu adequadamente.
- d. O valor de "Mu" refere-se ao coeficiente de regularização usado durante o treinamento de uma rede neural com o algoritmo de treinamento de Levenberg-Marquardt. Esse coeficiente controla a influência da regularização no processo de ajuste dos pesos da rede durante o treinamento.

Portanto, a avaliação do desempenho da configuração da rede e do processo de treinamento sugere que a rede foi treinada rapidamente e alcançou um baixo erro de desempenho.

A Figura 23 apresenta-se o gráfico da performance da rede neural durante o treino, mostrando o erro quadrático médio (*Mean Squared Error* - mse) ao longo de 1000 épocas (passagem de treinamento em todo o conjunto de dados de treinamento). Observa-se que o erro diminuiu significativamente nas primeiras épocas e depois estabilizou, com um ligeiro declínio contínuo até o final das 1000 épocas.

Figura 23 - Performance e supervisão do aprendizado

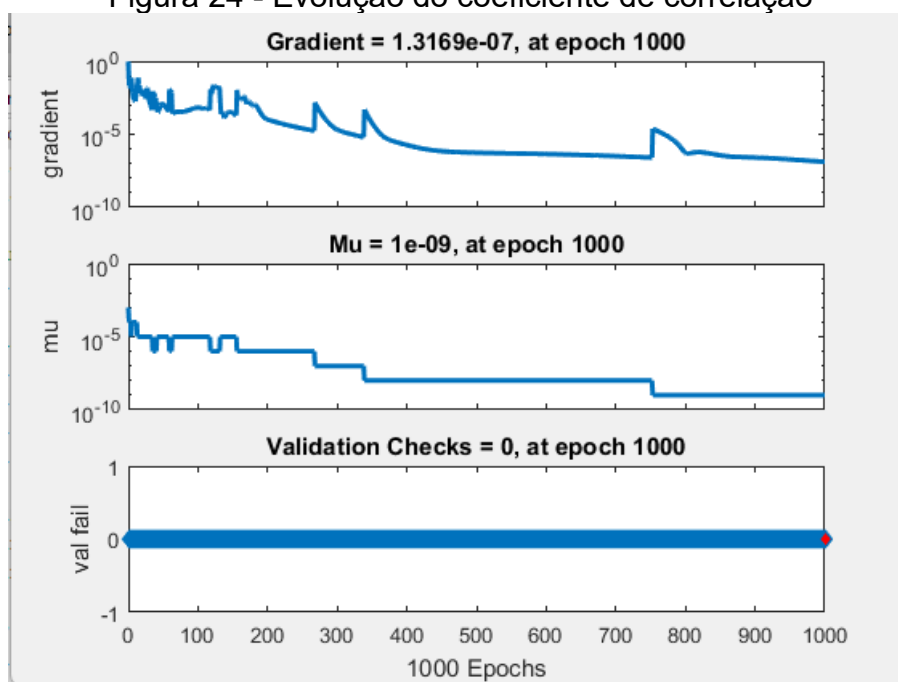


Fonte: O autor (2024).

A linha azul sólida representa o erro de treino, enquanto a linha pontilhada indica a melhor performance alcançada ao longo do treino, que foi de 0,003012 na época 1000. O círculo azul no final da linha sólida sugere que este é o ponto final do treino, onde o erro de treino se estabilizou. Ao analisar apenas os resultados apresentados na Figura 23, pode-se concluir que o treinamento poderia ter sido interrompido em torno de 200 épocas. É importante ressaltar que se trata de uma conclusão equivocada, pois é necessário avaliar, também, a evolução do coeficiente de correlação. Os pesos e bias podem sofrer pequenas alterações, mas podem alterar gradiente de forma significativa, como é possível observar na Figura 24.

A rede neural teve uma aprendizagem rápida no início do treino, o que é indicado pela queda acentuada no erro. A redução no erro tornou-se mais gradual após as primeiras 100 épocas, o que é comum à medida que a rede começa a convergir para uma solução. A estabilização do erro sugere que a rede pode ter alcançado a sua capacidade máxima de aprendizagem com os dados e arquitetura atuais. Na Figura 24 apresenta-se os gráficos do gradiente, parâmetro μ e os números de verificações.

Figura 24 - Evolução do coeficiente de correlação



Fonte: O autor (2024).

O primeiro gráfico apresenta o gradiente ao longo das épocas, começando com valores maiores e diminuindo ao longo do tempo. No final das 1000 épocas, o gradiente está em 1.3169×10^{-7} , o que indica uma mudança muito pequena nos pesos da rede, sugerindo que o treinamento pode ter convergido devido a estabilização dos valores.


O parâmetro Mu é um parâmetro de atualização de peso no treinamento de redes neurais. Seu valor inicial é alto e diminui ao longo das épocas, estabilizando-se próximo a 1×10^{-9} no final do treinamento. Esse parâmetro é usado para controlar a magnitude das atualizações de peso e pode ajudar a evitar oscilações durante o treinamento.

O terceiro gráfico mostra que o número de verificações de validação permanece em zero ao longo das 1000 épocas. Isso geralmente significa que o modelo não está sobre ajustando aos dados de treino, uma vez que não houve aumento no erro de validação que desencadeasse uma parada antecipada do treinamento.

Na Figura 25 apresenta-se o histograma de erro em relação ao valor predito e aos valores reais. Observa-se que a maior parte dos erros está concentrada na faixa central que representa o zero erro, indicando que a rede neural tem uma boa precisão, já que a maioria das previsões está muito próxima ou igual aos valores reais. Isso é

um bom sinal de que a rede está realizando previsões acuradas para os dados de treino.

Figura 25 - Histograma de erro em relação ao valor predito e aos valores errados



Fonte: O autor, (2024)


Na Figura 26 apresenta-se o desempenho obtido em relação aos dados reais na forma de correlação entre os dados. Os pontos de dados d (Data) são representados pelos círculos vazios e correspondem aos valores previstos pela rede neural versus os valores reais (targets).

A linha azul é a de ajuste (Fit), a qual mostra a relação entre as saídas previstas pela rede neural e os valores reais. Quanto mais próxima essa linha estiver de uma função identidade (onde a saída é igual ao alvo), melhor a rede está realizando as previsões. A linha identidade ($Y=T$) é linha pontilhada preta que representa a linha ideal, onde a saída prevista é exatamente igual ao valor real.

O Coeficiente de Correlação (R) obtido apresentou um valor $R=0,9803$, indicando um elevado nível de correlação entre as saídas previstas pela rede neural e os valores reais uma vez que valores de R próximos de 1 significam uma forte correlação positiva.

Analisando a Figura 26, pode-se concluir que o desempenho da rede neural é bom, uma vez que a linha de ajuste está bem próxima da linha identidade e o coeficiente de correlação é alto (0,9803). Isso sugere que as previsões da rede neural estão alinhadas com os valores reais, o que é desejável em uma tarefa de previsão.

Figura 26 - Desempenho obtido em relação aos dados reais



Fonte: O autor (2024)

4.6 PREDIÇÕES PARA NOVOS DADOS DE ENTRADA

Depois de treinar a RNA, esta ferramenta foi utilizada para fazer as previsões em novos dados de entrada. Foi alimentado um novo conjunto de dados de entrada chamado *novoDadoEntrada*, que possui o mesmo formato que os dados de entrada usados para treinar a rede. Foi utilizado a função *sim* para obter as previsões da rede neural para esses novos dados de entrada. A partir do novo dado de entrada (Tabela 5) chamado *novoDadoEntrada*, foi utilizado o código apresentado na Figura 28 para obter as previsões da rede neural:

Importante certificar de que `novoDadoEntrada` esteja no formato correto (um vetor de tamanho 10 neste caso, correspondente ao número de entradas da sua rede neural). A variável `previsões` contém a saída prevista pela rede neural para o novo dado de entrada (Figura 27). Foi utilizado como padrão 13 para liberado e 14 para reprocesso.

Figura 27 - Comandos utilizados para previsões

```

>> % Suponha que você tenha um novo dado de entrada chamado novoDadoEntrada

novoDadoEntrada = [10005406, 40927, 1, 86, 14, 2, 8, 256.12, 3.12,10];

% Exemplo de novo dado de entrada

% Obter previsões da rede neural para o novo dado de entrada

previsoes = sim(redeNeural, novoDadoEntrada');

% Exibir previsões

disp('Previsões da rede neural para o novo dado de entrada:'); disp(previsoes);
Previsões da rede neural para o novo dado de entrada:
    13.0002

>>

```

Fonte: O autor, (2024).

Na Tabela 4 apresenta-se os dados utilizados do novo conjunto de dados para a avaliação da predição da rede neural desenvolvida.

Tabela 4 - Dados utilizados para previsão do resultado apresentado pela rede

Dados	Valores
Receita	7
Artigo	4
Tear	1
%PA	86
%PUE	14
Fornecedor fio	2
Fornecedor elastano -	8
Gráfico	6
% Corante	3.12
Relação de banho	9

Fonte: O autor (2024).

Dado o valor previsto de saída de 13.0002, é indicativo de que este lote será liberado.

Além desta predição, foram feitas outras conforme apresentado na Tabela 5.

Tabela 5 - Predição de novos valores de entrada

Receita	Artigo	Tear	% PA	% PUE	Fio	Elastano	Gráfico Tingimento	% corante	Relação de Banho	Qualidade Real	Qualidade Predito
7	3	3	90.15	9.85	2	10	6	3.12	9	13	13
7	3	55	90,15	9,85	2	10	6	3,12	9	13	13
7	4	96	86	14	2	10	1	2,06	7	13	13
7	3	60	90,15	9,85	3	11	6	3,12	9	13	13
20	5	62	90.5	9.5	4	12	5	5.49	7	14	14
7	3	3	90,15	9,85	2	8	6	3,12	9	13	13
7	3	60	90,15	9,85	2	10	6	3,12	9	13	13
43	3	54	90.15	9.85	3	11	6	6	9	13	13
48	3	95	86	14	4	11	1	2.63	9	13	13
31	12	65	92.3	7.7	3	12	8	0.67	22	13	13

Fonte: O autor (2024).

Dos 10 lotes testados, apenas um necessitou de reprocesso, tanto na qualidade real quanto na qualidade predita. Isso indica que as previsões estão em concordância estreita com os valores observados, sugerindo que a rede neural está corretamente predizendo os casos em que ocorrerá reprocesso.

5 CONCLUSÕES

As taxas mais elevadas de reprocessamento identificadas nas fibras de poliamida sugerem desafios distintos em suas respectivas cadeias de produção. Sendo a poliamida uma fibra sintética, passa por processos complexos e pode gerar produtos fora das especificações devido a variações de parâmetros químicos e físicos. O levantamento realizado indicou que a elevada porcentagem de ocorrências indefinidas de reprocessamento na fibra de poliamida revela desafios na identificação precisa das causas, possivelmente decorrentes da complexidade dos processos e da dificuldade em monitorar todas as variáveis envolvidas.

Explorou-se o uso de técnicas de aprendizado de máquina, em particular redes neurais, para prever se um lote de tingimento será reprocessado ou liberado. Esta proposta não é explorada na literatura pois identificou-se que redes neurais são empregadas no processo de tingimento, em sua maioria, para predição de características de cor e identificação de defeitos – ou seja, por análise de padrões. Foi desenvolvido um modelo preditivo que pudesse auxiliar no processo de tomada de decisão na indústria têxtil, que pode contribuir para a redução de custos e o aumento da eficiência operacional.

Por meio de seleção e configuração de arquitetura de rede, funções de ativação e algoritmos de treinamento, foi possível desenvolver uma rede neural que demonstrou uma capacidade significativa de generalização. O modelo treinado foi capaz de fazer previsões sobre a necessidade de reprocessamento de lotes de tingimento com base nas características fornecidas como entrada.

O modelo desenvolvido neste estudo tem o potencial de ser integrado ao fluxo de trabalho existente na indústria têxtil ao automatizar esses dados de saída da rede junto ao sistema de Business Intelligence (BI) da empresa estudada, proporcionando benefícios significativos em termos de qualidade, eficiência e custo. Essa integração sugerida para trabalhos futuros seria uma maneira eficaz de utilizar os resultados da rede neural para melhorar os processos industriais de forma mais ampla e integrada. Resultados mais precisos demandariam investimentos em sensores, parada da planta, instalação e sincronia de todas as malhas de controle, o que pode ser realizado numa parada de manutenção preventiva. Certamente, os benefícios financeiros e de produção serão bastante significativos, já que a aplicação de redes neurais para a predição de lotes que devem ser reprovados/aprovados se mostrou bastante viável.

À medida que se dispor de maior conhecimento do processo, como por exemplo, a composição das receitas dos corantes e dados físico-químicas da água, estimamos que o reprocesso seja minimizado significativamente. E justamente essa é a sugestão para trabalhos futuros.

Assim, ressalta-se que este trabalho representa apenas um primeiro passo na utilização de técnicas de aprendizado de máquina para otimização de processos na indústria têxtil, e como sugestões para trabalhos futuros sugere-se ampliar o conjunto de variáveis de entrada da rede, como utilizar valores de pH e dados de análise água, ampliar para todas as máquinas de tingimento e também, incluir experimentar diferentes arquiteturas de rede neural. Isso pode resultar em um aprimoramento da precisão da ferramenta.

REFERÊNCIAS

ABDELILEH, M., BEN Ticha, M., KORDOGHLI, B. et al. Dyeing of Modified Acrylic Fibers with Indigo Carmine: Modeling and Optimization of the Dyeing Process Using a Combination of RSM and ANN Methodologies. *Fibers Polym* 24, 2377–2389 (2023). <https://doi.org/10.1007/s12221-023-00243-3>

AZIM, Gamil Abdel. Identification of Textile Defects Based on GLCM and Neural Networks. **Journal of Computer and Communications**. v 3 n.12, Dec 2015. <http://dx.doi.org/10.4236/jcc.2015.312001>

ABIT- Associação Brasileira da Indústria Têxtil e de Confecção. **Perfil do Setor 2022**. Disponível em: <https://www.abit.org.br/cont/perfil-do-setor>. Acesso em: 12 set. 2023.
ABIT- Associação Brasileira da Indústria Têxtil e de Confecção. **Indústria têxtil brasileira**. 2018. Disponível em: <https://www.abit.org.br/>. Acesso em: 12 set. 2023.

ADANUR, Sabit. Handbook of industrial textiles. Lancaster: Wellington Sears Company, 2017. 839 p.

BAHLMANN, Claus; HEIDEMANN, Gunther; RITTER, Helge. Artificial neural networks for automated quality control of textile seams. **Pattern Recognition**, [S.L.], v. 32, n. 6, p. 1049-1060, jun. 1999. Elsevier BV. [http://dx.doi.org/10.1016/s0031-3203\(98\)00128-9](http://dx.doi.org/10.1016/s0031-3203(98)00128-9).

BARANI, Hossein; MONTAZER, Majid. A Review on Applications of Liposomes in Textile Processing. **Journal Of Liposome Research**, [S.L.], v. 18, n. 3, p. 249-262, jan. 2008. Informa UK Limited. <http://dx.doi.org/10.1080/08982100802354665>.

BASYIGIT Zeynep Omerogullari , EYUPOGLU Can , EYUPOGLU Seyda , MERDAN Nigar. Investigation and feed-forward neural network-based estimation of dyeing properties of air plasma treated wool fabric dyed with natural dye obtained from Hibiscus sabdariffa. **Coloration Technology**, v 139, p441-453 , Aug 2023. <https://doi.org/10.1111/cote.12665>

BEALE, R; JACKSON, T. **Neural Computing - An Introduction**. Eua: Crc Press, 1990. 256 p.

BROADBENT, Arthur D. Basic Principles of Textile Coloration. West Yorkshire: Society Of Dyers And Colourists, 2011. 579 p.

CHATTOPADHYAY, R.; GUHA, A. ARTIFICIAL NEURAL NETWORKS: applications to textiles. **Textile Progress**, [S.L.], v. 35, n. 1, p. 1-46, mar. 2004. Informa UK Limited. <http://dx.doi.org/10.1080/00405160408688961>.

CHEN, Chun-Liang. Value Creation by SMEs Participating in Global Value Chains under Industry 4.0 Trend: case study of textile industry in taiwan. **Journal Of Global Information Technology Management**, [S.L.], v. 22, n. 2, p. 120-145, 3 abr. 2019. Informa UK Limited. <http://dx.doi.org/10.1080/1097198x.2019.1603512>.

DORAN, Enver Can; SAHIN, Cenk. The prediction of quality characteristics of cotton/elastane core yarn using artificial neural networks and support vector machines. **Textile Research Journal**, [S.L.], v. 90, n. 13-14, p. 1558-1580, 27 dez. 2019. SAGE Publications. <http://dx.doi.org/10.1177/0040517519896761>.

DUARTE, Adriana Yumi Sato. **Proposta de integração entre ferramentas de avaliação de ciclo de vida do produto e Indústria 4.0 (Industrie 4.0): estudo de caso da indústria têxtil e de confecção brasileira**. 2017. 125 f. Tese (Doutorado) - Curso de Engenharia Mecânica, Centro Tecnológico, Universidade Estadual de Campinas, Campinas, 2017.

ELEMEN Seniha , KUMBASAR Emriye Perrin Akçakoca, YAPAR Saadet . Modeling The Adsorption Of Textile Dye On Organoclay Using An Artificial Neural Network. **Dyes and Pigments**. v. 95, p 102-111, Oct 2012. <https://doi.org/10.1016/j.dyepig.2012.03.001>

EYUPOGLU, Can; EYUPOGLU, Seyda; MERDAN, Nigar; BASYIGIT, Zeynep Omerogullari. Natural dyeing of air plasma-treated wool fabric with *Rubia tinctorum* L. and prediction of dyeing properties using an artificial neural network. **Coloration Technology**, v 140, p 91 – 102, Feb 2024. <https://doi.org/10.1111/cote.12700>

FALANI, Leila Araújo; AGUIAR, Catia Rosana Lange de; FORNO, Ana Julia dal. Mapeamento da literatura sobre as tecnologias da indústria 4.0 no segmento têxtil brasileiro. **Brazilian Journal Of Development**, [S.L.], v. 6, n. 7, p. 42437-42452, 2020. Brazilian Journal of Development. <http://dx.doi.org/10.34117/bjdv6n7-019>.

FINOCCHIO, M. A. F. **Noções de redes neurais artificiais**, Universidade Tecnológica Federal do Paraná, 2014.

FUJITA, Renata Mayumi Lopes; JORENTE, Maria José. A indústria têxtil no Brasil: uma perspectiva histórica e cultural. **Modapalavra E-Periódico**, [S.L.], v. 8, n. 15, p. 153-174, 1 jan. 2015. Universidade do Estado de Santa Catarina. <http://dx.doi.org/10.5965/1982615x08152015153>.

FURFERI Rocco, GOVERNI Lapo, VOLPE Yary. Modelling and simulation of an innovative fabric coating process using artificial neural networks. **Textile Research Journal**, v. 82(12) p. 1282-1294, mar 2012 <https://doi.org/10.1177/0040517512436828>

GIORDANO, J. B.; **Tratamento térmico em materiais têxteis compostos de fibras sintéticas**., p. 13535-13542 . In: Anais do XX Congresso Brasileiro de Engenharia Química - COBEQ 2014 [= Blucher Chemical Engineering Proceedings, v.1, n.2]. São Paulo: Blucher, 2015. ISSN 2359-1757, DOI 10.5151/chemeng-cobeq2014-0651-24590-140729

GONDIM, Mauricio Lopes. **Estudos comparativo do ângulo de contato em tecido de malha de poliamida tratados com plasma**. 2016. 68 f. Dissertação (Mestrado) - Curso de Têxtil e Moda, Escola de Artes Ciências e Humanidades, Universidade de São Paulo, São Paulo, 2016.

HAJI, A., VADOOD, M. Environmentally Benign Dyeing of Polyester Fabric with Madder: Modelling by Artificial Neural Network and Fuzzy Logic Optimized by Genetic Algorithm. *Fibers Polym* 22, 3351–3357 (2021). <https://doi.org/10.1007/s12221-021-1161-0>

HASSABIS, Demis; KUMARAN, Dharshan; SUMMERFIELD, Christopher; BOTVINICK, Matthew. Neuroscience-Inspired Artificial Intelligence. *Neuron*, [S.L.], v. 95, n. 2, p. 245-258, jul. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.neuron.2017.06.011>.

HUI, Patrick C.L.; CHAN, Keith C.C.; YEUNG, K.W.; NG, Freny S.F.. Application of artificial neural networks to the prediction of sewing performance of fabrics. *International Journal Of Clothing Science And Technology*, [S.L.], v. 19, n. 5, p. 291-318, 9 out. 2007. Emerald. <http://dx.doi.org/10.1108/09556220710819500>.

INSTITUTO DE ESTUDOS E MARKETING INDUSTRIAL LTDA - IEMI **O Panorama Setorial da Indústria Têxtil Brasileira**. 2022. IEMI. Disponível em: <https://www.iemi.com.br/brasil-textil-2022/>. Acesso em: 26 out. 2023.

INSTITUTO DE ESTUDOS E MARKETING INDUSTRIAL LTDA - IEMI. Brasil têxtil: relatório setorial da indústria têxtil brasileira 2017. São Paulo, v.17, n.17, 2021.

JEYARAJ, Pandia Rajan; NADAR, Edward Rajan Samuel. Effective textile quality processing and an accurate inspection system using the advanced deep learning technique. *Textile Research Journal*, [S.L.], v. 90, n. 9-10, p. 971-980, 23 out. 2019. SAGE Publications. <http://dx.doi.org/10.1177/0040517519884124>.

JEONG Soohwan , LIM Jonghun , HONG Seok Il , KWON Soon Chul , SHIM Jae Yun , YOO Yup , CHO Hyungtae , LIM Sungsu , KIM Junghwan. A framework for environmental production of textile dyeing process using novel exhaustion-rate meter and multi-layer perceptron-based prediction model. *Process Safety and Environmental Protection*, v.175 (2023), p. 99-110, Jul 2023. Elsevier <https://doi.org/10.1016/j.psep.2023.05.009>

JOSHI, Manasi; NERURKAR, Madhura; BADHE, Pallavi; ADIVAREKAR, Ravindra. Scouring of cotton using marine pectinase. *Journal Of Molecular Catalysis B: Enzymatic*, [S.L.], v. 98, p. 106-113. Elsevier BV. <http://dx.doi.org/10.1016/j.molcatb.2013.10.010>.

KANT, Rita. Textile dyeing industry an environmental hazard. *Natural Science*, [S.L.], v. 04, n. 01, p. 22-26, 2012. Scientific Research Publishing, Inc.. <http://dx.doi.org/10.4236/ns.2012.41004>.

KETEMA, Asnake; WORKU, Amare. Review on Intermolecular Forces between Dyes Used for Polyester Dyeing and Polyester Fiber. *Journal Of Chemistry*, [S.L.], v. 2020, p. 1-7, 8 nov. 2020. Hindawi Limited. <http://dx.doi.org/10.1155/2020/6628404>.

KU, Chien-Chun; CHIEN, Chen-Fu; MA, Kang-Ting. Digital transformation to empower smart production for Industry 3.5 and an empirical study for textile dyeing. **Computers & Industrial Engineering**, [S.L.], v. 142, p. 106297, abr. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.cie.2020.106297>.

KUMAR, Harsh; KAUR, Gagandeep; PRIYA. Influence of tetra ethyl ammonium bromide (C₂H₅)₄NBr on the aggregation behavior of surface active ionic liquid 1-tetradecyl-3-methylimidazolium bromide [C₁₄mim][Br]. **Journal Of Molecular Liquids**, [S.L.], v. 313, p. 113431, set. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.molliq.2020.113431>.

LI, Wenxia; WEI, Zihan; LIU, Zhengdong; DU, Yujun; ZHENG, Jiahui; WANG, Huaping; ZHANG, Shuo. Qualitative identification of waste textiles based on near-infrared spectroscopy and the back propagation artificial neural network. **Textile Research Journal**, [S.L.], v. 91, n. 21-22, p. 2459-2467, 9 abr. 2021. SAGE Publications. <http://dx.doi.org/10.1177/00405175211007516>.

LIU, Jun; CHANG, Huihong; FORREST, Jeffrey Yi-Lin; YANG, Baohua. Influence of artificial intelligence on technological innovation: evidence from the panel data of china's manufacturing sectors. **Technological Forecasting And Social Change**, [S.L.], v. 158, p. 120142, set. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.techfore.2020.120142>.

MADHU, Amit; CHAKRABORTY, J.N.. Developments in application of enzymes for textile processing. **Journal Of Cleaner Production**, [S.L.], v. 145, p. 114-133, mar. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.jclepro.2017.01.013>.

MALUF, E.; KOLBE, W. Dados Técnicos para a Indústria Têxtil. 2.ed. São Paulo: IPT – Instituto de Pesquisas Tecnológicas do Estado de São Paulo: ABIT – Associação Brasileira da Indústria Têxtil e de Confecção, 2003.

MATHIS, Michael R.; KHETERPAL, Sachin; NAJARIAN, Kayvan. Artificial Intelligence for Anesthesia: what the practicing clinician needs to know. **Anesthesiology**, [S.L.], v. 129, n. 4, p. 619-622, 1 out. 2018. Ovid Technologies (Wolters Kluwer Health). <http://dx.doi.org/10.1097/aln.0000000000002384>.

PIMENTEL, Renê Coppe; LIMA, Iran Siqueira. Relação trimestral de longo prazo entre indicadores de liquidez e de rentabilidade: evidência de empresas do setor têxtil. **Revista de Administração**, [S.L.], v. 46, n. 3, p. 275-289, 14 set. 2011. Business Department, School of Economics, Business & Accounting USP. <http://dx.doi.org/10.5700/rausp1012>.

RAMESH, An; KAMBHAMPATI, C; MONSON, Jrt; DREW, Pj. Artificial intelligence in medicine. **Annals of The Royal College Of Surgeons Of England**, [S.L.], v. 86, n. 5, p. 334-338, 1 set. 2004. Royal College of Surgeons of England. <http://dx.doi.org/10.1308/147870804290>.

ROSA, Jorge Marcos; GUERHARDT, Flavio; RIBEIRO JÚNIOR, Silvestre Eduardo Rocha; BELAN, Peterson A.; LIMA, Gustavo A.; SANTANA, José Carlos Curvelo; BERSSANETI, Fernando Tobal; TAMBOURGI, Elias Basile; VANALE, Rosangela

Maria; ARAĐJO, Sidnei Alves de. Modeling and optimization of reactive cotton dyeing using response surface methodology combined with artificial neural network and particle swarm techniques. **Clean Technologies And Environmental Policy**, [S.L.], v. 23, n. 8, p. 2357-2367, 23 jun. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10098-021-02142-8>.

RUSCHIONI, P. B.; ALFIERI, P.; Estudo da influência da temperatura de termofixação 76 nas propriedades físicas de malhas de poliamida 6.6. *Química Têxtil* n ° 99. São Paulo. Junho, 2010. Pg. 52-61.

ŞAHIN, Cenk., BALCI, Onur., IŞIK, Melek., GÖKENÇ, İlker.. Artificial neural networks approach for prediction of CIELab values for yarn after dyeing and finishing process. **The Journal of The Textile Institute**, 114(9),1326–1335, 23 Sep 2022. <https://doi.org/10.1080/00405000.2022.2124629>

SALEM, Vidal. Tingimento têxtil: fibras, conceitos e tecnologias. São Paulo: Edgard Blucher, 2010. 297 p.

SALEM, Vidal; DE MARCHI, Alessandro; MENEZES, Felipe Gonçalves de. O beneficiamento têxtil na prática. 1. ed. São Paulo: Golden Química do Brasil, 2005.

SAMSAMI, Shakiba; MOHAMADIZANIANI, Maryam; SARRAFZADEH, Mohammad-Hossein; RENE, Eldon R.; FIROOZBAHR, Meysam. Recent advances in the treatment of dye-containing wastewater from textile industries: overview and perspectives. **Process Safety And Environmental Protection**, [S.L.], v. 143, p. 138-163, nov. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.psep.2020.05.034>.

SANDIN, Gustav; PETERS, Greg M.. Environmental impact of textile reuse and recycling – A review. **Journal Of Cleaner Production**, [S.L.], v. 184, p. 353-365, maio 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.jclepro.2018.02.266>.

SCHWARZ, Ivana; KOVAČEVIĆ, Stana. Textile Application: from need to imagination. **Textiles For Advanced Applications**, [S.L.], v. 1, n. 5, p. 312-325, 20 set. 2017. InTech. <http://dx.doi.org/10.5772/intechopen.68376>.

SIKKA, Monica Puri; SARKAR, Alok; GARG, Samridhi. Artificial intelligence (AI) in textile industry operational modernization. **Research Journal Of Textile And Apparel**, [S.L.], p. 258-268, 12 abr. 2022. Emerald. <http://dx.doi.org/10.1108/rjta-04-2021-0046>.

SINCLAIR, R. **Textiles and Fashion: materials, design and technology**. Eua: Elsevier, 2014. 328 p.

SMIRNOV, Evgeny A.; TIMOSHENKO, Denis M.; ANDRIANOV, Serge N.. Comparison of Regularization Methods for ImageNet Classification with Deep Convolutional Neural Networks. **Aasri Procedia**, [S.L.], v. 6, p. 89-94, 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.aasri.2014.05.013>.

SU, Kuan-Hua; LIN, Jia-Horng; LIN, Chih-Ching. Influence of reprocessing on the mechanical properties and structure of polyamide 6. **Journal Of Materials**

Processing Technology, [S.L.], v. 192-193, p. 532-538, out. 2007. Elsevier BV. <http://dx.doi.org/10.1016/j.jimatprotec.2007.04.056>.

UDDIN, Faheem. Environmental hazard in textile dyeing wastewater from local textile industry. **Cellulose**, [S.L.], v. 28, n. 17, p. 10715-10739, 2 out. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10570-021-04228-4>.

VADOOD, M.; HAJI, A. Application of ANN Weighted by Optimization Algorithms to Predict the Color Coordinates of Cellulosic Fabric in Dyeing with Binary Mix of Natural Dyes. *Coatings* 2022, 12, 1519. <https://doi.org/10.3390/coatings12101519>

VIBHAV Tiwari, SAMAR Garg, SAMARTH Bhat Y, SANCHIT Kumar, MANIKANDAN J, P MATHIAZHAGAN, Prakash Bhat, M. Tamilselvan, S. Periyasamy, "Design of a Real-Time Warp and Weft Measurement System for Fabric Analysis in Textile Testing Using Machine Learning", 2023 International Conference on Network, Multimedia and Information Technology (NMITCON), p.1-7, 2023.

VIGO, Tyrone L. **Textile processing and properties: preparation, dyeing, finishing and performance**. 3. ed. Amsterdam: Elsevier Science B.V., 2002. 486 p.

ZHANG, Jianlei; HE, Lin; CHENG, Longdi. Is China's Textile Industry Still a Labour-Intensive Industry? **Fibres And Textiles In Eastern Europe**, [S.L.], v. 29, n. 1145, p. 13-16, 28 fev. 2021. Walter de Gruyter GmbH. <http://dx.doi.org/10.5604/01.3001.0014.5038>.

ZHANG, Shan; REN, Yanfei; ZHAO, Hongzhi; HAN, Lei; YANG, Guangqing; LIU, Yu; FANG, Kuanjun. Short wet-steaming low-carbon cleaner pad dyeing of cotton/polyamide/lyocell fabric with reactive dyes. **Industrial Crops And Products**, [S.L.], v. 197, p. 116556, jul. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.indcrop.2023.116556>.

APÊNDICE A - Dados identificados para serem utilizados no Matlab.

Receita	Artigo	Peso	Tear	%PA	%PUE	Fornecedor Fio	Fornecedor Elastano	Gráfico Tingimento	% corante	Relação de Banho	Qualidade
1	1	403,76	3	250	0	Fornecedor 1	Fornecedor 5	1	2,1	1	liberado
2	2	233,13	3	24	9	Fornecedor 3	Fornecedor 9	2	3,35	2	liberado
2	2	232,63	3	24	9	Fornecedor 3	Fornecedor 9	2	3,35	2	liberado
3	3	267,95	58	90,15	14	Fornecedor 3	Fornecedor 8	3	3,19	3	liberado
3	3	267,29	58	90,15	14	Fornecedor 3	Fornecedor 8	3	3,19	4	liberado
3	4	260,63	99	86	14	Fornecedor 2	Fornecedor 7	3	3,19	5	liberado
3	4	262,74	99	86	14	Fornecedor 2	Fornecedor 7	3	3,19	5	liberado
4	3	262,08	59	90,15	14	Fornecedor 2	Fornecedor 7	1	2,63	6	liberado
4	3	262,17	99	86	14	Fornecedor 2	Fornecedor 7	1	3,19	5	liberado
5	4	263,54	95	86	14	Fornecedor 2	Fornecedor 7	4	0,8	6	liberado
5	4	260,75	67	86	14	Fornecedor 2	Fornecedor 7	4	0,8	6	liberado
5	4	262,74	95	86	14	Fornecedor 2	Fornecedor 7	4	0,8	6	liberado
5	4	261,44	99	86	14	Fornecedor 2	Fornecedor 7	4	0,8	6	liberado
6	4	261,63	67	86	14	Fornecedor 2	Fornecedor 7	5	2,18	7	liberado
6	4	260,6	67	86	14	Fornecedor 2	Fornecedor 7	5	2,18	8	liberado
7	3	522,06	27	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	9	liberado
7	3	260,28	27	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	9	liberado
7	3	264,29	47	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	9	liberado
7	5	521,72	56	90,5	9,5	Fornecedor 3	Fornecedor 9	6	3,1	25	liberado
7	3	520,69	27	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
8	4	264,99	3	86	14	Fornecedor 2	Fornecedor 7	3	2,03	11	liberado
8	4	26174	3	86	14	Fornecedor 2	Fornecedor 7	3	2,03	11	liberado
8	4	115	3	86	14	Fornecedor 2	Fornecedor 7	3	2,03	12	liberado
8	4	264,66	3	86	14	Fornecedor 2	Fornecedor 7	3	2,03	12	liberado
9	6	260,3	55	90,5	9,5	Fornecedor 3	Fornecedor 9	5	1,69	13	liberado
9	6	5,68	55	90,5	9,5	Fornecedor 3	Fornecedor 9	5	1,69	13	liberado

25	4	259,57	96	86	14	Fornecedor 2	Fornecedor 7	5	0,95	25	liberado
25	4	260,58	99	86	14	Fornecedor 2	Fornecedor 7	5	0,95	25	liberado
11	4	523,24	99	86	14	Fornecedor 2	Fornecedor 7	5	2,93	25	liberado
25	4	263,72	3	86	14	Fornecedor 2	Fornecedor 6	5	3,99	14	liberado
25	4	264,39	3	86	14	Fornecedor 2	Fornecedor 6	5	3,99	15	liberado
13	4	5	3	86	14	Fornecedor 2	Fornecedor 6	5	1,01	15	liberado
13	4	264,86	3	86	14	Fornecedor 2	Fornecedor 6	5	1,01	15	liberado
13	4	264,95	3	86	14	Fornecedor 2	Fornecedor 6	5	1,01	15	liberado
13	4	5,18	3	86	14	Fornecedor 2	Fornecedor 6	5	1,01	15	liberado
14	4	26177	3	86	14	Fornecedor 2	Fornecedor 7	5	2	15	liberado
14	4	266,72	3	86	14	Fornecedor 2	Fornecedor 7	5	2,99	15	liberado
14	4	5,08	3	86	14	Fornecedor 2	Fornecedor 7	5	2,99	15	liberado
14	4	264,77	3	86	14	Fornecedor 2	Fornecedor 7	5	2,99	15	liberado
25	4	263,22	3	86	14	Fornecedor 2	Fornecedor 7	5	2,49	16	liberado
25	4	263,71	3	86	14	Fornecedor 2	Fornecedor 7	5	2,48	17	liberado
25	4	263,49	3	86	14	Fornecedor 2	Fornecedor 7	5	2,48	17	liberado
25	4	262,29	3	86	14	Fornecedor 2	Fornecedor 7	5	2,48	16	liberado
15	4	262,65	3	86	14	Fornecedor 2	Fornecedor 7	2	0,82	6	liberado
15	4	261,35	3	86	14	Fornecedor 2	Fornecedor 7	2	0,82	6	liberado
16	3	260,54	61	90,15	14	Fornecedor 3	Fornecedor 8	5	0,69	5	liberado
16	3	262,39	61	90,15	14	Fornecedor 3	Fornecedor 8	5	0,69	5	liberado
17	4	521,27	99	86	14	Fornecedor 2	Fornecedor 7	2	1,67	25	reprocesso
18	3	527,9	58	90,15	14	Fornecedor 3	Fornecedor 8	7	2,14	25	liberado
6	3	270,73	53	90,15	14	Fornecedor 3	Fornecedor 8	5	2,18	18	liberado
6	3	264,01	61	90,15	14	Fornecedor 3	Fornecedor 8	5	2,18	18	liberado
19	4	524,85	3	90,15	14	Fornecedor 2	Fornecedor 7	7	2,18	18	reprocesso
20	5	260,47	62	90,5	9,5	Fornecedor 4	Fornecedor 9	5	5,51	7	reprocesso
20	5	261,18	62	90,5	9,5	Fornecedor 4	Fornecedor 9	5	2,51	7	reprocesso
21	4	264,16	3	86	14	Fornecedor 2	Fornecedor 7	5	2,45	19	liberado
21	4	263,01	67	86	14	Fornecedor 2	Fornecedor 7	5	2,45	19	liberado

22	4	262,7	97	86	14	Fornecedor 2	Fornecedor 7	5	2,1	25	liberado
22	4	257,15	49	86	14	Fornecedor 2	Fornecedor 7	5	2,1	25	liberado
23	1	197,27	70	250	0	Fornecedor 1	Fornecedor 7	2	2,58	20	liberado
23	1	197,08	70	250	0	Fornecedor 1	Fornecedor 7	2	2,58	20	liberado
23	1	197,27	70	250	0	Fornecedor 1	Fornecedor 7	2	2,58	21	liberado
23	1	197,08	70	250	0	Fornecedor 1	Fornecedor 7	2	2,58	21	liberado
24	7	165,63	65	92,3	7,7	Fornecedor 3	Fornecedor 9	8	0,67	22	liberado
24	7	16117	65	92,3	7,7	Fornecedor 3	Fornecedor 9	8	0,67	22	liberado
25	4	263,04	96	86	14	Fornecedor 2	Fornecedor 7	7	1,69	23	liberado
25	4	263,3	96	86	14	Fornecedor 2	Fornecedor 7	7	1,69	23	liberado
17	4	262,33	97	86	14	Fornecedor 2	Fornecedor 7	2	1,67	24	liberado
17	4	262,44	65	86	14	Fornecedor 2	Fornecedor 7	2	1,67	24	liberado
26	4	259,61	49	86	14	Fornecedor 2	Fornecedor 7	5	2,27	25	liberado
26	4	2549	49	86	14	Fornecedor 2	Fornecedor 7	5	2,27	25	liberado
26	4	261,6	99	86	14	Fornecedor 2	Fornecedor 7	5	2,27	25	liberado
26	4	259,69	99	86	14	Fornecedor 2	Fornecedor 7	5	2,27	25	liberado
27	4	260,41	250	86	14	Fornecedor 2	Fornecedor 7	5	1,52	25	liberado
27	4	259,53	250	86	14	Fornecedor 2	Fornecedor 7	5	1,52	25	liberado
28	4	264,58	3	86	14	Fornecedor 2	Fornecedor 7	9	5,52	26	liberado
28	4	263,97	3	86	14	Fornecedor 2	Fornecedor 7	9	5,52	26	liberado
29	4	264,32	3	86	14	Fornecedor 2	Fornecedor 7	1	2,31	26	liberado
29	4	264,14	3	86	14	Fornecedor 2	Fornecedor 7	1	2,31	26	liberado
30	4	524,99	66	86	14	Fornecedor 2	Fornecedor 7	5	2,47	25	liberado
17	4	520,99	95	86	14	Fornecedor 2	Fornecedor 7	2	1,67	25	liberado
29	4	292,41	99	86	14	Fornecedor 2	Fornecedor 7	1	2,31	27	liberado
29	4	224,93	99	86	14	Fornecedor 2	Fornecedor 7	1	2,31	27	liberado
7	3	261,89	23	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	24	liberado
7	3	262,88	59	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	24	liberado
31	4	2530	99	86	14	Fornecedor 2	Fornecedor 7	5	1,37	25	liberado
31	4	260,43	99	86	14	Fornecedor 2	Fornecedor 7	5	1,37	25	liberado

31	4	262,56	66	86	14	Fornecedor 2	Fornecedor 7	5	1,37	25	liberado
31	4	263,09	66	86	14	Fornecedor 2	Fornecedor 7	5	1,37	25	liberado
31	4	261,57	97	86	14	Fornecedor 2	Fornecedor 7	5	1,37	25	liberado
31	4	260,02	97	86	14	Fornecedor 2	Fornecedor 7	5	1,37	25	liberado
31	4	260,24	66	86	14	Fornecedor 2	Fornecedor 7	5	1,37	25	liberado
31	4	131,1	66	86	14	Fornecedor 2	Fornecedor 7	5	1,37	25	liberado
31	4	130,9	66	86	14	Fornecedor 2	Fornecedor 7	5	1,37	25	liberado
6	4	262,22	52	86	14	Fornecedor 2	Fornecedor 7	5	2,18	14	liberado
6	4	5,89	52	86	14	Fornecedor 2	Fornecedor 7	5	2,18	14	liberado
32	4	47	65	86	14	Fornecedor 2	Fornecedor 7	2	1,24	25	liberado
32	4	262,21	66	86	14	Fornecedor 2	Fornecedor 7	2	1,24	25	liberado
8	4	262,43	52	86	14	Fornecedor 2	Fornecedor 7	3	2,03	28	liberado
8	4	264,58	52	86	14	Fornecedor 2	Fornecedor 7	3	2,03	28	liberado
33	4	260,06	250	86	14	Fornecedor 2	Fornecedor 7	5	2,25	29	liberado
33	4	261,1	250	86	14	Fornecedor 2	Fornecedor 7	5	2,25	29	liberado
7	3	515,49	57	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
34	8	262,25	19	90,5	9,5	Fornecedor 3	Fornecedor 9	1	1,68	24	reprocesso
34	8	262,27	19	90,5	9,5	Fornecedor 4	Fornecedor 9	1	1,68	24	liberado
35	3	523,25	61	90,15	14	Fornecedor 3	Fornecedor 8	25	0,18	25	liberado
36	4	261,04	95	86	14	Fornecedor 2	Fornecedor 7	11	0,24	7	liberado
36	4	260,68	95	86	14	Fornecedor 2	Fornecedor 7	11	0,24	7	liberado
37	4	262,96	3	86	14	Fornecedor 2	Fornecedor 7	5	1,26	19	liberado
37	4	264,35	3	86	14	Fornecedor 2	Fornecedor 7	5	1,26	19	liberado
38	4	25276	95	86	14	Fornecedor 2	Fornecedor 7	5	4,29	25	liberado
38	4	260,03	95	86	14	Fornecedor 2	Fornecedor 7	5	4,29	25	liberado
38	4	262,22	52	86	14	Fornecedor 2	Fornecedor 7	5	4,29	25	liberado
38	4	261,67	66	86	14	Fornecedor 2	Fornecedor 7	5	4,29	25	liberado
39	4	224,23	99	86	14	Fornecedor 2	Fornecedor 7	2	1,08	30	liberado
39	4	224,38	99	86	14	Fornecedor 2	Fornecedor 7	2	1,08	30	liberado
39	4	518,79	99	86	14	Fornecedor 2	Fornecedor 7	2	1,08	25	liberado

40	4	571,77	99	86	14	Fornecedor 2	Fornecedor 7	1	2,06	25	liberado
39	4	524,73	3	86	14	Fornecedor 2	Fornecedor 7	2	1,08	25	liberado
32	4	524,9	3	86	14	Fornecedor 2	Fornecedor 7	2	1,24	25	liberado
4	9	295,62	95	86	14	Fornecedor 4	Fornecedor 8	1	2,63	25	liberado
4	9	225,34	95	86	14	Fornecedor 4	Fornecedor 8	1	2,63	25	liberado
3	4	523,75	3	86	14	Fornecedor 2	Fornecedor 7	3	3,19	25	liberado
33	4	521,05	3	86	14	Fornecedor 2	Fornecedor 7	5	2,25	25	liberado
41	4	262,18	96	86	14	Fornecedor 2	Fornecedor 7	5	1,34	25	liberado
41	4	261,02	96	86	14	Fornecedor 2	Fornecedor 7	5	1,34	25	liberado
18	4	522,77	3	86	14	Fornecedor 2	Fornecedor 6	25	0,22	25	liberado
43	3	521,17	58	90,15	14	Fornecedor 3	Fornecedor 8	11	0,38	25	liberado
44	3	520,69	58	90,15	14	Fornecedor 3	Fornecedor 8	1	3	25	liberado
43	3	518,14	61	90,15	14	Fornecedor 3	Fornecedor 8	3	2,56	25	liberado
44	4	600,22	97	86	14	Fornecedor 2	Fornecedor 7	5	2,2	25	liberado
21	3	523,23	59	90,15	14	Fornecedor 3	Fornecedor 8	5	2,45	25	liberado
39	3	261,82	3	90,15	14	Fornecedor 2	Fornecedor 5	2	1,08	31	liberado
39	3	266,31	3	90,15	14	Fornecedor 2	Fornecedor 5	2	1,08	31	liberado
41	3	521,18	61	90,15	14	Fornecedor 3	Fornecedor 8	5	1,34	25	reprocesso
43	3	521,49	47	90,15	14	Fornecedor 3	Fornecedor 8	3	2,56	25	liberado
43	3	519	54	90,15	14	Fornecedor 3	Fornecedor 8	3	2,56	25	liberado
45	25	524,455	252	84,25	185	Fornecedor 4	Fornecedor 9	6	3,1	25	liberado
7	4	524,4	96	86	14	Fornecedor 2	Fornecedor 6	6	3,1	25	liberado
1	1	403,76	3	86	14	Fornecedor 1	Fornecedor 5	6	3,1	25	liberado
7	4	593,5	3	86	14	Fornecedor 2	Fornecedor 6	6	3,1	25	liberado
7	3	522,73	3	90,15	14	Fornecedor 2	Fornecedor 6	6	3,1	25	liberado
7	3	525,1	55	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
46	11	467,19	9	90	25	Fornecedor 3	Fornecedor 9	13	0	25	reprocesso
46	11	522,83	9	90	25	Fornecedor 3	Fornecedor 9	13	0	25	liberado
46	11	460,41	9	90	25	Fornecedor 3	Fornecedor 9	13	0	25	liberado
7	4	587,95	250	86	14	Fornecedor 2	Fornecedor 6	6	3,1	25	liberado

7	3	520,6	62	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
15	3	524,66	55	90,15	14	Fornecedor 2	Fornecedor 7	2	0,82	25	liberado
15	3	521,02	62	90,15	14	Fornecedor 2	Fornecedor 7	2	0,82	25	liberado
4	3	520,63	62	90,15	14	Fornecedor 2	Fornecedor 7	1	2,63	25	liberado
47	4	592,25	96	86	14	Fornecedor 2	Fornecedor 7	1	3,1	25	liberado
46	11	397,449	9	90	25	Fornecedor 3	Fornecedor 9	13	0	13	liberado
46	25	458,15	9	90	25	Fornecedor 3	Fornecedor 9	13	0	25	liberado
48	3	520,23	61	90,15	14	Fornecedor 3	Fornecedor 8	3	1,79	25	reprocesso
49	13	459,49	3	90,5	9,5	Fornecedor 4	Fornecedor 9	5	2,02	25	liberado
49	13	456,88	3	90,5	9,5	Fornecedor 4	Fornecedor 9	5	2,02	25	liberado
14	4	524,96	250	86	14	Fornecedor 2	Fornecedor 7	5	2,99	25	reprocesso
14	4	524,52	95	86	14	Fornecedor 2	Fornecedor 7	5	2,99	25	liberado
48	3	520,23	61	90,15	14	Fornecedor 3	Fornecedor 8	3	1,79	25	reprocesso
40	4	526,82	66	86	14	Fornecedor 2	Fornecedor 7	1	2,06	25	liberado
7	3	513	61	90,15	14	Fornecedor 3	Fornecedor 8	6	3,7	25	reprocesso
40	4	5882	67	86	14	Fornecedor 2	Fornecedor 6	1	2,06	25	liberado
7	3	520,23	61	90,15	14	Fornecedor 3	Fornecedor 8	6	4,74	25	reprocesso
50	4	595,5	3	86	14	Fornecedor 2	Fornecedor 7	1	1,69	25	liberado
14	4	524,96	250	86	14	Fornecedor 2	Fornecedor 7	5	2,99	25	reprocesso
45	25	517,975	29	84,25	185	Fornecedor 4	Fornecedor 9	6	3,1	25	liberado
51	7	324,51	87	92,3	7,7	Fornecedor 3	Fornecedor 9	6	3,32	13	reprocesso
45	25	517,805	29	84,25	185	Fornecedor 4	Fornecedor 9	6	3,1	25	liberado
45	25	522,79	252	84,25	185	Fornecedor 4	Fornecedor 9	6	3,1	25	liberado
7	4	592,8	95	86	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
7	4	524,96	250	86	14	Fornecedor 2	Fornecedor 7	6	4,74	25	reprocesso
7	3	516,28	62	90,15	14	Fornecedor 2	Fornecedor 5	6	3,1	25	liberado
7	3	519,38	3	90,15	14	Fornecedor 2	Fornecedor 5	6	3,1	25	liberado
7	3	513,35	55	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
7	3	517,51	54	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
7	4	589,46	96	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado

1	1	395,45	3	250	0	Fornecedor 1	Fornecedor 7	1	2,1	25	liberado
52	1	395,07	3	250	0	Fornecedor 1	Fornecedor 7	6	4,36	25	liberado
53	14	260,24	19	88,8	11,2	Fornecedor 2	Fornecedor 5	6	2,99	8	liberado
53	14	267,88	9	88,8	11,2	Fornecedor 2	Fornecedor 5	6	2,99	8	liberado
7	3	520,86	58	90,15	14	Fornecedor 2	Fornecedor 5	6	3,1	25	liberado
41	3	524,41	3	90,15	14	Fornecedor 2	Fornecedor 7	5	1,34	25	liberado
17	3	526,41	3	90,15	14	Fornecedor 2	Fornecedor 7	2	1,67	25	liberado
54	4	588,72	96	90,15	14	Fornecedor 2	Fornecedor 7	2	1,67	25	liberado
55	15	393,03	69	86	14	Fornecedor 3	Fornecedor 9	1	3,07	25	liberado
7	3	521,82	3	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
7	3	521,99	3	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
40	3	522,85	3	90,15	14	Fornecedor 2	Fornecedor 7	1	2,06	25	liberado
7	3	515,66	5	90,15	14	Fornecedor 2	Fornecedor 7	6	4,74	25	reprocesso
56	16	330,62	32	92	8	Fornecedor 3	Fornecedor 9	6	3,73	13	liberado
50	4	520,52	95	86	14	Fornecedor 2	Fornecedor 6	1	1,69	25	liberado
40	3	516,01	54	90,15	14	Fornecedor 2	Fornecedor 7	1	2,06	25	liberado
7	3	523,22	44	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
7	3	526,76	3	90,15	14	Fornecedor 2	Fornecedor 7	6	3,1	25	liberado
40	3	5117	53	90,15	14	Fornecedor 2	Fornecedor 7	1	2,06	25	liberado
7	3	520,38	3	90,15	14	Fornecedor 2	Fornecedor 7	6	4,74	25	reprocesso
53	14	519,59	57	88,8	11,2	Fornecedor 2	Fornecedor 5	6	2,99	25	reprocesso

APÊNDICE B - Dados identificados para serem utilizados no Matlab.

Receita	Artigo	Tear	%PA	%PUE	Fornecedor Fio	Fornecedor Elastano	Gráfico Tingimento	% corante	Relação de Banho	Qualidade
1	1	3	100	0	1	8	1	2,1	1	13
2	2	3	91	9	3	12	2	3,35	2	13
2	2	3	91	9	3	12	2	3,35	2	13
3	3	58	90,15	9,85	3	11	3	3,19	3	13
3	3	58	90,15	9,85	3	11	3	3,19	4	13
3	4	99	86	14	2	10	3	3,19	5	13
3	4	99	86	14	2	10	3	3,19	5	13
4	3	59	90,15	9,85	2	10	1	2,63	6	13
4	3	99	86	14	2	10	1	3,19	5	13
5	4	95	86	14	2	10	4	0,8	6	13
5	4	67	86	14	2	10	4	0,8	6	13
5	4	95	86	14	2	10	4	0,8	6	13
5	4	99	86	14	2	10	4	0,8	6	13
6	4	67	86	14	2	10	5	2,42	7	13
6	4	67	86	14	2	10	5	2,42	8	13
7	3	27	90,15	9,85	2	10	6	3,12	9	13
7	3	27	90,15	9,85	2	10	6	3,12	9	13
7	3	47	90,15	9,85	2	10	6	3,12	9	13
7	5	56	90,5	9,5	3	12	6	3,12	25	13
7	3	27	90,15	9,85	2	10	6	3,12	25	13
8	4	3	86	14	2	10	3	2,03	11	13
8	4	3	86	14	2	10	3	2,03	11	13
8	4	3	86	14	2	10	3	2,03	12	13
8	4	3	86	14	2	10	3	2,03	12	13
9	6	55	90,5	9,5	3	12	5	1,69	13	13
9	6	55	90,5	9,5	3	12	5	1,69	13	13

25	4	96	86	14	2	10	5	0,95	25	13
25	4	99	86	14	2	10	5	0,95	25	13
11	4	99	86	14	2	10	5	2,93	25	13
25	4	3	86	14	2	9	5	3,99	14	13
25	4	3	86	14	2	9	5	3,99	15	13
13	4	3	86	14	2	9	5	1,01	15	13
13	4	3	86	14	2	9	5	1,01	15	13
13	4	3	86	14	2	9	5	1,01	15	13
13	4	3	86	14	2	9	5	1,01	15	13
14	4	3	86	14	2	10	5	2	15	13
14	4	3	86	14	2	10	5	2,99	15	13
14	4	3	86	14	2	10	5	2,99	15	13
14	4	3	86	14	2	10	5	2,99	15	13
25	4	3	86	14	2	10	5	2,49	16	13
25	4	3	86	14	2	10	5	2,48	17	13
25	4	3	86	14	2	10	5	2,48	17	13
25	4	3	86	14	2	10	5	2,48	16	13
15	4	3	86	14	2	10	2	0,82	6	13
15	4	3	86	14	2	10	2	0,82	6	13
16	3	61	90,15	9,85	3	11	5	0,69	5	13
16	3	61	90,15	9,85	3	11	5	0,69	5	13
17	4	99	86	14	2	10	2	1,67	25	14
18	3	58	90,15	9,85	3	11	7	2,14	25	13
6	3	53	90,15	9,85	3	11	5	2,42	18	13
6	3	61	90,15	9,85	3	11	5	2,42	18	13
19	4	3	90,15	9,85	2	10	7	2,42	18	14
20	5	62	90,5	9,5	4	12	5	5,51	7	14
20	5	62	90,5	9,5	4	12	5	2,51	7	14
21	4	3	86	14	2	10	5	2,45	19	13
21	4	67	86	14	2	10	5	2,45	19	13

22	4	97	86	14	2	10	5	2,1	25	13
22	4	49	86	14	2	10	5	2,1	25	13
23	1	70	100	0	1	10	2	2,58	20	13
23	1	70	100	0	1	10	2	2,58	20	13
23	1	70	100	0	1	10	2	2,58	21	13
23	1	70	100	0	1	10	2	2,58	21	13
24	7	65	92,3	7,7	3	12	8	0,67	22	13
24	7	65	92,3	7,7	3	12	8	0,67	22	13
25	4	96	86	14	2	10	7	1,69	23	13
25	4	96	86	14	2	10	7	1,69	23	13
17	4	97	86	14	2	10	2	1,67	24	13
17	4	65	86	14	2	10	2	1,67	24	13
26	4	49	86	14	2	10	5	2,27	25	13
26	4	49	86	14	2	10	5	2,27	25	13
26	4	99	86	14	2	10	5	2,27	25	13
26	4	99	86	14	2	10	5	2,27	25	13
27	4	100	86	14	2	10	5	1,52	25	13
27	4	100	86	14	2	10	5	1,52	25	13
28	4	3	86	14	2	10	9	5,52	26	13
28	4	3	86	14	2	10	9	5,52	26	13
29	4	3	86	14	2	10	1	2,31	26	13
29	4	3	86	14	2	10	1	2,31	26	13
30	4	66	86	14	2	10	5	2,47	25	13
17	4	95	86	14	2	10	2	1,67	25	13
29	4	99	86	14	2	10	1	2,31	27	13
29	4	99	86	14	2	10	1	2,31	27	13
7	3	23	90,15	9,85	2	10	6	3,12	24	13
7	3	59	90,15	9,85	2	10	6	3,12	24	13
31	4	99	86	14	2	10	5	1,37	25	13
31	4	99	86	14	2	10	5	1,37	25	13

31	4	66	86	14	2	10	5	1,37	25	13
31	4	66	86	14	2	10	5	1,37	25	13
31	4	97	86	14	2	10	5	1,37	25	13
31	4	97	86	14	2	10	5	1,37	25	13
31	4	66	86	14	2	10	5	1,37	25	13
31	4	66	86	14	2	10	5	1,37	25	13
31	4	66	86	14	2	10	5	1,37	25	13
6	4	52	86	14	2	10	5	2,42	14	13
6	4	52	86	14	2	10	5	2,42	14	13
32	4	65	86	14	2	10	2	1,24	25	13
32	4	66	86	14	2	10	2	1,24	25	13
8	4	52	86	14	2	10	3	2,03	28	13
8	4	52	86	14	2	10	3	2,03	28	13
33	4	100	86	14	2	10	5	2,25	29	13
33	4	100	86	14	2	10	5	2,25	29	13
7	3	57	90,15	9,85	2	10	6	3,12	25	13
34	8	19	90,5	9,5	5	12	1	1,68	24	14
34	8	19	90,5	9,5	5	12	1	1,68	24	13
35	3	61	90,15	9,85	3	11	25	0,18	25	13
36	4	95	86	14	2	10	11	0,24	7	13
36	4	95	86	14	2	10	11	0,24	7	13
37	4	3	86	14	2	10	5	1,26	19	13
37	4	3	86	14	2	10	5	1,26	19	13
38	4	95	86	14	2	10	5	4,29	25	13
38	4	95	86	14	2	10	5	4,29	25	13
38	4	52	86	14	2	10	5	4,29	25	13
38	4	66	86	14	2	10	5	4,29	25	13
39	4	99	86	14	2	10	2	1,08	30	13
39	4	99	86	14	2	10	2	1,08	30	13
39	4	99	86	14	2	10	2	1,08	25	13

40	4	99	86	14	2	10	1	2,06	25	13
39	4	3	86	14	2	10	2	1,08	25	13
32	4	3	86	14	2	10	2	1,24	25	13
4	9	95	86	14	4	11	1	2,63	25	13
4	9	95	86	14	4	11	1	2,63	25	13
3	4	3	86	14	2	10	3	3,19	25	13
33	4	3	86	14	2	10	5	2,25	25	13
41	4	96	86	14	2	10	5	1,34	25	13
41	4	96	86	14	2	10	5	1,34	25	13
18	4	3	86	14	2	9	25	0,22	25	13
43	3	58	90,15	9,85	3	11	11	0,38	25	13
44	3	58	90,15	9,85	3	11	1	3	25	13
43	3	61	90,15	9,85	3	11	3	2,56	25	13
44	4	97	86	14	2	10	5	2,2	25	13
21	3	59	90,15	9,85	3	11	5	2,45	25	13
39	3	3	90,15	9,85	2	8	2	1,08	31	13
39	3	3	90,15	9,85	2	8	2	1,08	31	13
41	3	61	90,15	9,85	3	11	5	1,34	25	14
43	3	47	90,15	9,85	3	11	3	2,56	25	13
43	3	54	90,15	9,85	3	11	3	2,56	25	13
45	25	102	84,25	15,75	4	12	6	3,1	25	13
7	4	96	86	14	2	9	6	3,12	25	13
1	1	3	86	14	1	8	6	3,12	25	13
7	4	3	86	14	2	9	6	3,12	25	13
7	3	3	90,15	9,85	2	9	6	3,12	25	13
7	3	55	90,15	9,85	2	10	6	3,12	25	13
46	11	9	90	10	5	12	13	0	25	14
46	11	9	90	10	5	12	13	0	25	13
46	11	9	90	10	5	12	13	0	25	13
7	4	100	86	14	2	9	6	3,12	25	13

7	3	62	90,15	9,85	2	10	6	3,12	25	13
15	3	55	90,15	9,85	2	10	2	0,82	25	13
15	3	62	90,15	9,85	2	10	2	0,82	25	13
4	3	62	90,15	9,85	2	10	1	2,63	25	13
47	4	96	86	14	2	10	1	3,12	25	13
46	11	9	90	10	5	12	13	0	13	13
46	25	9	90	10	5	12	13	0	25	13
48	3	61	90,15	9,85	3	11	3	1,79	25	14
49	13	3	90,5	9,5	4	12	5	2,02	25	13
49	13	3	90,5	9,5	4	12	5	2,02	25	13
14	4	100	86	14	2	10	5	2,99	25	14
14	4	95	86	14	2	10	5	2,99	25	13
48	3	61	90,15	9,85	3	11	3	1,79	25	14
40	4	66	86	14	2	10	1	2,06	25	13
7	3	61	90,15	9,85	3	11	6	3,7	25	14
40	4	67	86	14	2	9	1	2,06	25	13
7	3	61	90,15	9,85	3	11	6	4,74	25	14
50	4	3	86	14	2	10	1	1,69	25	13
14	4	100	86	14	2	10	5	2,99	25	14
45	25	98	84,25	15,75	4	12	6	3,1	25	13
51	7	87	92,3	7,7	3	12	6	3,32	13	14
45	25	98	84,25	15,75	4	12	6	3,1	25	13
45	25	102	84,25	15,75	4	12	6	3,1	25	13
7	4	95	86	14	2	10	6	3,1	25	13
7	4	100	86	14	2	10	6	4,74	25	14
7	3	62	90,15	9,85	2	8	6	3,12	25	13
7	3	3	90,15	9,85	2	8	6	3,12	25	13
7	3	55	90,15	9,85	2	10	6	3,12	25	13
7	3	54	90,15	9,85	2	10	6	3,12	25	13
7	4	96	90,15	9,85	2	10	6	3,12	25	13

1	1	3	100	0	1	10	1	2,1	25	13
52	1	3	100	0	1	10	6	4,36	25	13
53	14	19	88,8	11,2	2	8	6	2,99	8	13
53	14	9	88,8	11,2	2	8	6	2,99	8	13
7	3	58	90,15	9,85	2	8	6	3,12	25	13
41	3	3	90,15	9,85	2	10	5	1,34	25	13
17	3	3	90,15	9,85	2	10	2	1,67	25	13
54	4	96	90,15	9,85	2	10	2	1,67	25	13
55	15	69	86	14	5	12	1	3,07	25	13
7	3	3	90,15	9,85	2	10	6	3,12	25	13
7	3	3	90,15	9,85	2	10	6	3,12	25	13
40	3	3	90,15	9,85	2	10	1	2,06	25	13
7	3	5	90,15	9,85	2	10	6	4,74	25	14
56	16	32	92	8	3	12	6	3,73	13	13
50	4	95	86	14	2	9	1	1,69	25	13
40	3	54	90,15	9,85	2	10	1	2,06	25	13
7	3	44	90,15	9,85	2	10	6	3,12	25	13
7	3	3	90,15	9,85	2	10	6	3,12	25	13
40	3	53	90,15	9,85	2	10	1	2,06	25	13
7	3	3	90,15	9,85	2	10	6	4,74	25	14
53	14	57	88,8	11,2	2	8	6	2,99	25	14
