



Faculdade de Tecnologia de Americana "Ministro Ralph Biasi"
Curso Superior de Tecnologia em Produção Têxtil

VITOR HUGO BARROS

INTELIGÊNCIA ARTIFICIAL NA REVISÃO DE TECIDOS PLANOS

Americana, SP

2023

VITOR HUGO BARROS

INTELIGÊNCIA ARTIFICIAL NA REVISÃO DE TECIDOS PLANOS

Trabalho de graduação apresentado como exigência parcial para obtenção do título de Tecnólogo em Curso Superior de Tecnologia em Produção Têxtil pelo Centro Paula Souza – FATEC Faculdade de Tecnologia – Ministro Ralph Biasi. Área de concentração: Controle de Qualidade. Orientador: Prof. Dr. Daives Arakem Bergamasco.

Americana, SP

2023

BARROS, Vitor Hugo

Inteligência artificial na revisão de tecidos planos. / Vitor Hugo BARROS – Americana, 2023.

66f.

Monografia (Curso Superior de Tecnologia em Produção Têxtil) - - Faculdade de Tecnologia de Americana Ministro Ralph Biasi – Centro Estadual de Educação Tecnológica Paula Souza

Orientador: Prof. Dr. Daives Araken BERGAMASCO

1. Indústria de tecido plano 2. Inteligência artificial 3. Qualidade. I. BARROS, Vitor Hugo II. BERGAMASCO, Daives Araken III. Centro Estadual de Educação Tecnológica Paula Souza – Faculdade de Tecnologia de Americana Ministro Ralph Biasi

CDU: 677074

007.52

658.56

Elaborada pelo autor por meio de sistema automático gerador de ficha catalográfica da Fatec de Americana Ministro Ralph Biasi.

Vitor Hugo Barros

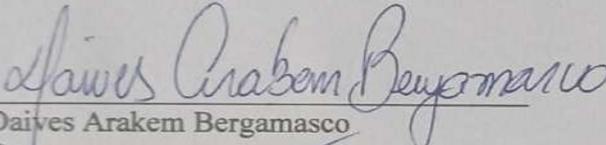
Inteligência artificial na revisão de tecidos planos

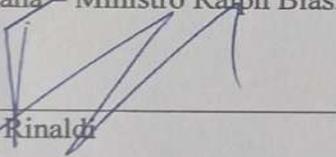
Trabalho de graduação apresentado como exigência parcial para obtenção do título de Tecnólogo em Curso Superior de Tecnologia em Produção Têxtil pelo Centro Paula Souza – FATEC Faculdade de Tecnologia de Americana – Ralph Biasi.

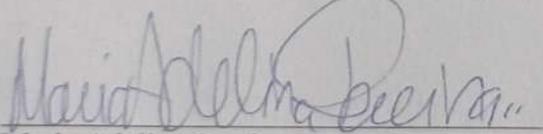
Área de concentração: Controle de qualidade

Americana, 29 de novembro de 2023

Banca Examinadora:


Daives Arakem Bergamasco
Doutor
FATEC Americana – Ministro Ralph Biasi


Fernando Cesar Rinaldi
Mestre
FATEC Americana – Ministro Ralph Biasi


Maria Adelina Pereira
Mestre
FATEC Americana – Ministro Ralph Biasi

VITOR HUGO BARROS

INTELIGÊNCIA ARTIFICIAL NA REVISÃO DE TECIDOS PLANOS

Trabalho de graduação apresentado
como exigência parcial para obtenção
do título de Tecnólogo em curso
superior de Tecnologia em Produção
Têxtil pelo Centro Paula Souza –
FATEC Faculdade de Tecnologia –
Ministro Ralph Biasi.
Área de concentração: Controle de
Qualidade

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão a todos que contribuíram para a realização deste trabalho. Em primeiro lugar agradeço a Deus pela força, sabedoria e orientação que me concedeu durante toda a jornada desta pesquisa.

Agradeço também aos professores Daives por sua orientação, apoio e sabedoria ao longo deste processo e ao Edison por sua dedicação e insights foram fundamentais para a concretização deste trabalho.

Aos meus familiares e amigos, principalmente o Ivan, a Sabrina e a Durvalina, meu sincero agradecimento pelo constante incentivo e compreensão durante os momentos dedicados a esta pesquisa. Suas palavras de encorajamento foram um suporte inestimável.

Por fim, agradeço a todos que, direta ou indiretamente, contribuíram para este trabalho, pois cada pequeno gesto e palavra de estímulo foi fundamental para a sua conclusão.

“Não se compõe uma sabedoria introduzindo no pensamento os resíduos diversos de todas as filosofias humanas, tal como não se fica com saúde engolindo o conteúdo de todos os frascos de uma velha farmácia.” (Victor Hugo).

RESUMO

A monografia “Inteligência Artificial na Revisão de Tecidos Planos” explora a aplicação de técnicas de inteligência artificial na qualidade da indústria têxtil, focando na classificação de tecidos planos e detecção de defeitos. Após uma introdução à IA destacando seu impacto na sociedade, a pesquisa aborda as redes neurais convolucionais como eficazes na análise de imagens, utilizando MNIST para exemplificar a classificação de imagens. Em seguida, a monografia se concentra no uso da base de dados DAGM para detecção de defeitos, descrevendo o pré-processamento das imagens e a arquitetura da rede. Os resultados revelam desafios iniciais na identificação de defeitos em alguns tipos de tecidos, com ênfase na necessidade de melhorias para superar o *overfitting*. Propõe-se a aplicação de *data augmentation* em classes como amostras escassas, resultando em melhorias nas taxas de acerto. Os resultados detalhados incluem matrizes de confusão e taxas de acerto por classe, evidenciando a eficácia do *data augmentation*.

Palavras-chave: *Classificação de tecidos; Inteligência Artificial; Tecidos planos.*

ABSTRACT

The monograph "Artificial Intelligence in Flat Fabric Inspection" explores the application of artificial intelligence techniques in the textile industry's quality control, with a focus on the classification of flat fabrics and defect detection. After an introduction to AI, highlighting its societal impact, the research delves into convolutional neural networks as effective tools for image analysis, using the MNIST dataset to exemplify image classification. Subsequently, the monograph focuses on utilizing the DAGM dataset for defect detection, describing image preprocessing and network architecture. The results reveal initial challenges in identifying defects in certain fabric types, emphasizing the need for improvements to overcome overfitting. The proposal includes the application of data augmentation in classes with limited samples, resulting in improved accuracy rates. Detailed outcomes comprise confusion matrices and accuracy rates per class, highlighting the effectiveness of data augmentation.

Keywords: Fabric classification; Artificial Intelligence; Flat fabrics.

LISTA DE FIGURAS

Figura 1 Representação da torção Z e S.....	17
Figura 2 Ciclo PDCA.....	21
Figura 3 Exemplo de iluminação Andon.....	22
Figura 4 Exemplo do Diagrama de Ishikawa	23
Figura 5 Exemplo Histograma	24
Figura 6 Exemplo gráfico de Pareto.....	25
Figura 7 Máquina revisadora de tecidos	27
Figura 8 Tabela de pontuação sistema de 4 pontos.....	29
Figura 9 Fio Grosso urdume	29
Figura 10 Trama misturada	30
Figura 11 Bolinha de engomagem	30
Figura 12 Urdume frouxo	31
Figura 13 Urdume esticado.....	31
Figura 14 Urdume duplo	31
Figura 15 Canastra	32
Figura 16 Nó de urdume	32
Figura 17 Ruptura de urdume.....	32
Figura 18 Trama misturada	33
Figura 19 Trama frouxa.....	33
Figura 20 Estripada.....	34
Figura 21 Trama dupla.....	34
Figura 22 Reintroduzida.....	34
Figura 23 Trama curta.....	35
Figura 24 Ruptura de trama.....	35
Figura 25 Falta de trama.....	35
Figura 26 Raleira e parada de tear	36
Figura 27 Variação de batidas	36
Figura 28 Pelotas.....	36
Figura 29 Esquema em blocos de rede neural	37
Figura 30 Exemplo de operações convolucionais.....	39
Figura 31 Exemplo de operação da camada pooling.....	40
Figura 32 Aplicação de max pooling para atingir downsampling	41

Figura 33 Imagem do elemento 5 da base MNIST sem normalização	43
Figura 34 Imagem do elemento 5 da base MNIST com normalização	43
Figura 35 Rede neural convolucional para classificar imagens do MNIST	44
Figura 36 Parâmetros para classificação no MNIST	45
Figura 37 Acurácia de convnet para classificar imagens de MNIST	45
Figura 38 Perde de convnet para classificar imagens de MNIST	46
Figura 39 Organização de pastas	47
Figura 40 Classes de tecidos sem defeitos	48
Figura 41 Classes de tecidos com defeitos	48
Figura 42 Tecido sem defeito da classe 4 após pré-processamento da VGG16	49
Figura 43 Rede neural convolucional para classificar tecidos	50
Figura 44 Acurácia da convnet para classificar imagens de tecidos	51
Figura 45 Perda de convnet para classificar imagens de tecidos	51
Figura 46 Matriz de confusão para classificação de tecidos	52
Figura 47 Ilustração de processamento com funções do TensorFlow	53
Figura 48 Rede neural convolucional com mudanças no pré-processamento	54
Figura 49 Acurácia da convnet com melhorias para classificar defeitos em tecidos	55
Figura 50 Perda da convnet para classificar imagens de tecidos	55
Figura 51 Matriz de confusão de rede com melhorias aplicadas para classificar tecidos	56
Figura 52 Taxas de aproveitamento para classificação de tecidos com pré-processamento melhorado	56
Figura 53 Exemplo de data augmentation	58
Figura 54 Acurácia de convnet com data augmentation para classificar tecidos da classe 2	59
Figura 55 Perda de convnet com data augmentation para classificar tecidos da classe 2	59
Figura 56 Matriz de confusão com data augmentation para classificar tecidos da classe 2	60
Figura 57 Comparação de taxa de aproveitamento com e sem data augmentation na classe 2	60
Figura 58 Figura 54 Acurácia de convnet com data augmentation para classificar tecidos da classe 5	61

Figura 59 Perda de convnet com data augmentation para classificar tecidos da classe 5.....	61
Figura 60 Matriz de confusão com data augmentation para classificar tecidos da classe 5.....	62
Figura 61 Comparação de taxa de aproveitamento com e sem data augmentation na classe 5.....	62

SUMÁRIO

1	INTRODUÇÃO.....	14
2	REVISÃO BIBLIOGRÁFICA	16
2.1	ALGODÃO.....	16
2.2	FIAÇÃO	17
2.3	TECELAGEM.....	18
2.4	QUALIDADE NA INDÚSTRIA TÊXTIL	20
2.4.1	PROCESSOS PARA CONTROLE DE QUALIDADE.....	20
2.4.2	CLASSIFICAÇÃO DE TECIDOS NA TECELAGEM.....	25
3	INTELIÊNCIA ARTIFICIAL	37
3.1	FERRAMENTAS PARA APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL.....	41
3.2	IMPLEMENTAÇÃO DA INTELIGÊNCIA ARTIFICIAL.....	42
3.3	DETECÇÃO DE DEFEITOS COM INTELIGÊNCIA ARTIFICIAL	46
4	IMPLEMENTAÇÃO DE INTELIGÊNCIA ARTIFICIAL NO PROCESSO DE REVISÃO.....	63
4.1	COLETA DE DADOS PARA TREINAMENTO	63
4.2	TREINAMENTO DE UM MODELO DE IA	63
4.3	IMPLEMENTAÇÃO PROGRESSIVA	63
4.4	MELHORIAS CONTÍNUAS	63
4.5	ANÁLISE DE DADOS.....	63
5	CONCLUSÃO	65
	REFERÊNCIAS	67

1 INTRODUÇÃO

No cenário atual, a Inteligência Artificial (IA) tem emergido como uma tecnologia transformadora que influencia significativamente vários aspectos da vida cotidiana e impulsiona inovações em uma ampla gama de setores. Seu potencial revolucionário não está limitado a apenas uma área, mas se estende a várias disciplinas e aplicações. A IA é uma área multidisciplinar que envolve a criação de algoritmos e modelos capazes de aprender, raciocinar e tomar decisões, imitando, até certo ponto, a inteligência humana.

A qualidade é um dos pilares que impulsionam o sucesso de qualquer indústria e setor. No contexto de fabricação e classificação de tecidos planos, a qualidade desempenha um papel crucial, afetando tanto a eficiência operacional quanto a satisfação do cliente. A garantia da qualidade envolve a capacidade de produzir produtos que atendam ou excedam os padrões predefinidos, minimizando defeitos e mantendo consistência em todo o processo de produção. Tradicionalmente, a avaliação da qualidade em processos de classificação de tecidos planos foi uma tarefa manual suscetível a erros e que demandava um tempo significativo.

No entanto, com os avanços na IA e no aprendizado de máquina, tornou-se possível automatizar a avaliação da qualidade, melhorando a precisão e eficiência de processos de classificação de tecidos planos. Este trabalho se concentra precisamente na capacidade da IA de otimizar a qualidade na classificação de tecidos planos, contribuindo para a redução de defeitos e aprimoramento de padrões de qualidade.

Este documento tem como objetivo explorar a aplicação prática da IA na classificação de tecidos planos, destacando a eficácia do uso de redes neurais convolucionais (CNNs) para essa finalidade. As CNNs têm demonstrado grande potencial na análise de imagens e têm sido fundamentais para o desenvolvimento de sistemas de visão computacional. Estas redes têm a capacidade de aprender a representação de características relevantes nas imagens, tornando-as ideais para a tarefa de classificação de tecidos planos, contribuindo diretamente para a melhoria da qualidade.

Nossa pesquisa também demonstra que a IA não se limita apenas à classificação de tecidos planos, mas é uma tecnologia altamente versátil que pode

ser aplicada em uma variedade de contextos e setores, todos com o objetivo comum de melhorar a qualidade. Por meio da automação dessa tarefa, a IA oferece uma solução eficaz para melhorar a qualidade do produto, reduzir a margem de erro e atender a padrões rigorosos de qualidade.

Assim, este estudo oferece uma visão abrangente sobre como a IA e as CNNs podem ser aplicadas com sucesso na classificação de tecidos planos, melhorando a qualidade em diversos processos de fabricação e análise. Ilustra seu potencial para automatizar tarefas complexas e destaca sua importância contínua na era da inovação tecnológica, que não só promove a eficiência, mas também eleva os padrões de qualidade em todo o espectro da indústria.

2 REVISÃO BIBLIOGRÁFICA

2.1 ALGODÃO

Há 3 mil anos atrás, o algodão já era conhecido entre os povos, mesmo com a garantia histórica que a China tecia panos de algodão por volta do ano 2000 a.C., é importante ressaltar que os povos da Índia já comercializavam tecidos de algodão desde 2600 a.C. qual estendeu esse comercio para outros povos o trocando por lã na Mesopotâmia e esse intermédio de mercadores indianos que fez o algodão chegar até o Egito, que o espalhou para o leste do Mediterrâneo. E assim o algodão percorreu da Índia para o Oriente Médio, depois para o Egito, logo após para a África, em seguida a Macedônia, na Grécia, Roma e finalmente no sul da Europa.

De nome científico *Gossypium hirsutum*, o algodão é produzido pelo algodoeiro, planta da família das malváceas, suas fibras crescem em conjunto com suas sementes dentro de um capulho, ou cápsula, que desabrocha quando maduro. Sendo uma planta de regiões tropicais, tem muitas dificuldades em climas frios. O clima pode fazer com que tenha variações em sua altura indo de 1,5 m a 6 m. Seu período vegetativo dura de cinco a sete meses, de acordo com a quantidade de calor recebido.

“As fibras do algodão são classificadas de acordo com seu comprimento. Inferiores, se menores de 22 mm; médias, se medirem de 28 mm a 34 mm; longas, se tiverem mais de 34 mm de comprimento”. (Pezzolo, 2017, p. 42).

Nos dias atuais, a fibra de algodão é a mais importante utilizada em indústrias têxteis, diversos motivos dão toda essa importância ao algodão como: ser mais lavável e resistente que a lã, seu tratamento químico além de ser econômico, não requer preparação mecânica e a parte não utilizada pelo setor têxtil pode ser aproveitado em outros ambientes, como seu caroço que pode ser extraído óleo comestível e ao moer todos os seus resíduos, seu farelo pode ser utilizado na alimentação do gado ou como fertilizante.

Sendo a tecelagem a responsável por fazer os tecidos ganharem forma, o papel da fiação é essencial na cadeia têxtil, pois é lá que as fibras e filamentos se transformam em fios. Antes de se tornarem fios, as fibras são preparadas para que fiquem homogêneas e paralelas, passando por uma sequência de máquinas quais vão deixar as fibras, limpas, estiradas e lhes darão torção, esse processo deixara os fios com a consonância necessária para o tear fazer sua parte na cadeia têxtil.

Podendo ser obtidos de fibras naturais e pela extrusão de fibras químicas (sintéticas ou artificiais) os fios podem ser constituídos de um único filamento (monofilamento) ou por

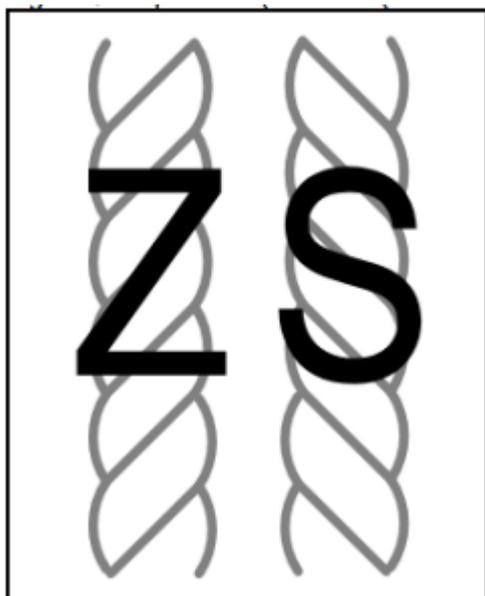
um conjunto de dois ou mais filamento (multifilamento). É chamado de filamento contínuo quando o comprimento do fio é indefinido, isso ocorre com o acetato, náilon, poliéster e outras fibras químicas, quais podem chegar a quilômetros de comprimento.

2.2 FIAÇÃO

Na fiação também ocorre a texturização no caso de fibras químicas (sintéticas ou artificiais), que as transformam de lisos e duros, em fios macios, cheios, fofos, com aspecto encrespado, com maior volume e elasticidade, essas propriedades caracterizam o fio para a fiação, sendo feitos com a utilização de processos mecânicos e térmicos que oscilam dependendo do produto resultante.

Os fios destinados ao uso têxtil podem ser obtidos através de dois processos: fiação a anela e fiação por rotor (Open-End). A fiação a anel, também conhecida como convencional (CO), é utilizada para fibras curtas e fibras longas, qualquer um dos casos pode ser obtido fios cardados e fios penteados, esse tipo de fio costumam oferecer mais resistência, porém seu custo é maior comparado com o Open-End. A torção do fio feito pelo processo a anel, pode ser no sentido direito (Z) ou no sentido esquerdo (S). Realizada de fora da fibra para dentro, a torção deixa o fio com um aspecto mais macio no seu núcleo e em uma superfície conforme apresenta a figura 1.

Figura 1 Representação da torção Z e S.



Fonte: Nicolau, 2022

Já na fiação por rotor, também conhecida por Open-End (OE), o custo é bem menor graças a simplificação na formação do fio e o produto final é mais regular que o fiado a anel (fio convencional), porém sua resistência é menor. Esse método é o mais prático para produção de fios, por isso na maioria das vezes ele é utilizado para aproveitar resíduos de outros sistemas e tem resultados melhores na utilização das fibras mais curtas do que o processo convencional. Comumente as fiações possuem uma linha para fios de anel e outra de fios Open-End para aproveitar os resíduos.

Conforme (Pezzolo, 2017) os tipos de fios podem ser divididos em quatro grupos. Fio penteado, qual passa por uma máquina chamada penteadeira, que elimina as fibras mais curtas e as impurezas que não foram retiradas anteriormente, esse processo condiz com mais qualidade, resistência e resultado regular no fio, garantindo uma menor formação de bolinhas (pilling) no tecido acabado. Já o fio cardado por não passar na penteadeira, possui mais fibras curtas que além de proporcionar a formação de bolinhas (pilling) pode gerar defeito na regularidade do fio (neps). Existem também o fio fantasia, que através do beneficiamento adquire propriedades em seu aspecto ou toque para diferenciá-lo com o intuito de agregar valor e diversificar o tecido. Enquanto o fio tinto é colorido antes de entrar na tecelagem.

2.3 TECELAGEM

Considerada uma das artes mais antigas do mundo, a tecelagem, surgiu como forma de proteção, nos abrigos eram utilizados tramas de galhos e folhas para se resguardar, esse trabalho também era utilizado para proteger o corpo. Os primeiros tecidos nasceram da manipulação das fibras com os dedos dando origem à cestaria e de sua evolução os primeiros tecidos, com a descoberta de novos desenhos nos modos de entrelaçar foi sendo descoberto outras texturas.

Por séculos as etapas da produção têxtil permaneceram com trabalhos manuais, atualmente as máquinas permitem o entrelaçamento entre dois conjuntos de fios no sentido horizontal e vertical, o tear tem seu funcionamento baseado em alguns elementos essenciais que são chamados de urdume, trama, cala e pente.

O urdume é o nome dado para um conjunto de fios tensos, colocados paralelamente no sentido do comprimento do tear, ele também pode ser conhecido como urdidura. Em conjunto com o urdume temos a trama, fios passados no sentido transversal entre os fios da urdidura em uma abertura conhecida por cala, que é

aberta pelo pente que tem a função de levantar e abaixar alternadamente os fios de urdume fazendo com que a trama se entrelace para assim formar o tecido.

De acordo com (Pezzolo, 2017) apenas entrelaçar os fios não é suficiente para a determinar sua estrutura, sendo assim o tecido pode ter vários padrões, os principais padrões de ligamentos ao cruzar o fio de urdume com o de trama são: ligamento tafetá, ligamento sarja e ligamento cetim.

O ligamento tafetá o mais simples das padronagens caracterizado pela distribuição inversa de fios ímpares e pares, aonde cada fio de trama irá passar de maneira alternada por cima e por baixo de cada fio do urdume, deixando o tecido com uma aparência de tabuleiro. Quando o tecido obtém de linhas diagonais que na maioria das vezes tem ângulo de 45° o nome dado é ligamento sarja, com a característica de deixar seu lado direito e avesso nitidamente diferentes esse tipo de padronagem costuma passar em baixo um fio de urdume para passar sobre dois e repetir o processo. Também com avesso e direito diferentes temos o ligamento cetim, qual tem seu lado direito brilhante, ele resulta em um tecido liso, graças a sua disseminação dos pontos de cruzamento entre os fios.

Os tecidos planos é o principal tipo de tecido, sua característica primordial é seu entrelaçamento formando um ângulo de 90° com o urdume no sentido longitudinal do tecido e a trama no sentido contrário, os tecidos planos têm algumas variedades como liso, maquinado, jacquard e estampado.

O tecido liso apresenta aspecto uniforme, não possui estampa, feito de ligamento tafetá, sarja ou cetim a parte mais importante do tecido liso é que seu acabamento deve valorizar os fios e sua padronagem. O tecido maquinado tem uma apresentação mais fantasiosa, que é obtida pelos fios de trama ou com tratamentos em seu acabamento. O tecido jacquard pode contém diversos desenhos em sua estrutura de entrelaçamento, que podem variar a cor e no brilho, sua característica final resulta no cruzamento livre do urdume e trama.

Os tecidos podem ter várias colorações, alvejados, tintos, mesclados, estampados, listrados, xadrezes e até mesmo crus que é quando o tecido não sofre acabamento úmido após serem tecidos, os tecidos alvejados passam por alvejamento/branqueamento, os tintos ganham uma coloração única em toda sua extensão, os mesclados são resultados da mistura entre fios ou fios diferentes, quais não aceitam o mesmo tipo de coloração, os tecidos estampados tem desenhos feitos por corantes em áreas específicas enquanto os tecidos listrados e xadrezes ganham

propriedades que diferenciam o urdume e a trama partindo do objetivo de qual estilo escolher.

2.4 QUALIDADE NA INDÚSTRIA TÊXTIL

Conforme a Associação Brasileira da Indústria Têxtil (ABIT, 2023), as indústrias têxteis brasileiras em conjunto com as de confecções, foram responsáveis no ano de 2021 pelo faturamento de R\$ 190 bilhões, empregando 1,34 milhão de pessoas, adicionando os trabalhadores indiretos esse número chega a 8 milhões representando um total de 19,5% de trabalhadores alocados na produção industrial.

O Brasil é a maior Cadeia Têxtil completa do ocidente, contemplando desde a produção de fibras, como a plantação de algodão, até os desfiles de moda (ABIT, 2023). Devido essa importância no cenário industrial e sua competitividade global, os problemas relacionados com a qualidade não são novidades para as organizações e aparecem desde o início do setor. As inúmeras variáveis como: matéria-prima, máquinas, produtos e até mesmo colaboradores devem estar em sintonia para amenizar essas dificuldades, em razão dos problemas que podem afetar diretamente os processos industriais constantemente são realizadas pesquisas e estudos para adequação e padronização de processos visando desenvolver qualidade na indústria têxtil.

2.4.1 PROCESSOS PARA CONTROLE DE QUALIDADE

O conceito de qualidade deve ser dado a um tipo de serviço ou processo, para que atenda perfeitamente às necessidades dos clientes como o mercado é extremamente competitivo a qualidade do produto pode se tornar um diferencial, isso acaba colaborando para destacar a empresa de seus concorrentes.

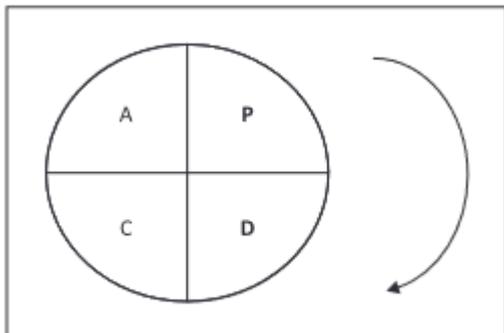
De acordo com (Guariete & de Larmelina, 2016) há muito tempo um produtor sabia exatamente as especificações e necessidades que seus consumidores tinham.

Ainda conforme (Guariete & de Larmelina, 2016) dessa forma ele tinha total conhecimento da reputação da qualidade de seu produto e sua propaganda era feita através de seus clientes.

Esse cenário foi totalmente alterado na chegada da Revolução Industrial com o conceito de produção em grande escala, foi adotado pelas empresas um método de padronização e repetição qual substituiu o modelo de produção por customização pelo método de padronização e repetição de atividades.

Na década de 1920, Walter A. Shewhart, levou o controle estatístico para as empresas, utilizando gráficos de controle para monitoração de resultados nos processos contínuos de produção. Shewhart também propôs o ciclo PDCA (Planejar – *Plan*, Executar – *Do*, Verificar – *Check* e Agir – *Act*) como ilustra a figura 2.

Figura 2 Ciclo PDCA



Fonte: Paladini, et al, 2012

De acordo com (Raush, 2022, p. 57) a ferramenta PDCA aborda diferentes estruturas de um processo, desde o planejamento da ação, até a fabricação de um produto, mantendo a ação, até a fabricação do produto, mantendo-se um ciclo de melhoria contínua. Para tal conquista é necessário a prática de treinamentos com a equipe em relação as ferramentas da qualidade, fazendo com que todos os envolvidos tenham ciência da necessidade e como implementá-las.

Outra técnica que pode ser utilizada para o controle em produção é o *Andon* conforme (Raush, 2022, p. 24) o *Andon* advém da metodologia *jidoka*, muito utilizada pelo sistema Toyota de produção e significa um termo japonês para lâmpada. Utilizando a gestão visual dos operadores como sua principal função o sistema ajuda na verificação de erros nos procedimentos e nos produtos, auxiliando que eles não prossigam evitando assim custos adicionais.

A barra de luz pode ser utilizada em máquinas, ser acionado de maneira automática ou manual em que se acende uma luz apontando, em caso de qualquer defeito que parasse o processo podendo ser vista de distâncias consideráveis.

Cada cor utilizada na barra reflete a um defeito ou erro que pode ser ocasionado. Estes erros vão desde a falha do processo em si, mas também, a uma possível falta de óleo ou necessidade de manutenção (Raush, 2022, p. 24). Ainda conforme (Raush, 2022, p. 26), a Toyota possuía um lema interessante “para a

produção – para que a produção nunca pare”. Na figura 3 é possível observar o *Andon* sendo utilizado em indústrias Toyota.

Figura 3 Exemplo de iluminação Andon



Fonte: Avani, 2023

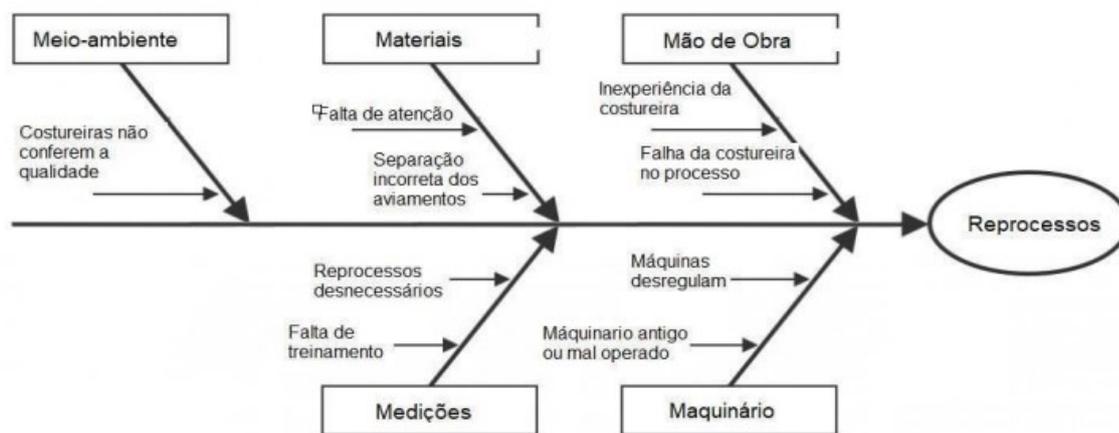
Conforme (Dennis, 2008, p. 111) os membros da equipe Toyota foram encorajados a identificar problemas e utilizar o *Andon* o que fazia a linha parar o tempo todo, o que desencadeava uma intensa procura pela solução dos problemas. (Dennis, 2008, p. 111) ainda diz que ao terem que recomeçar a linha identificando e tratando as causas de origem e assim melhorava a competência de contenção do processo.

Para melhor aplicação do *Andon* analisando os ocorridos é possível fazer a utilização do diagrama de causa-efeito que também é conhecido como gráfico de espinha de peixe ou diagrama de Ishikawa, essa ferramenta tem o objetivo de fazer análise das operações dos processos produtivos.

De acordo com (Montgomery, 2017, p. 247) Uma vez que um defeito, erro ou problema tenha sido identificado e isolado para estudo posterior, devemos começar a analisar as causas potenciais desse efeito indesejável. Em um contexto em que as situações não são óbvias o diagrama de Ishikawa é uma ferramenta bastante útil para

expor causas potenciais. Criado em 1943 pelo engenheiro japonês Karou Ishikawa e com sua estrutura similar à de uma espinha de peixe vide figura 4, o diagrama de causa efeito ilustra as causas principais de uma ação, de um resultado ou de uma determinada situação. A lógica do diagrama conforme (Paladini, et al., 2012, p. 360) o fluxo apresentado evidencia causas que conduzem a determinados efeitos. Assim se o efeito é nocivo, as causas podem ser eliminadas, pode-se conferir consistência a elas.

Figura 4 Exemplo do Diagrama de Ishikawa



Fonte: Raush, 2022

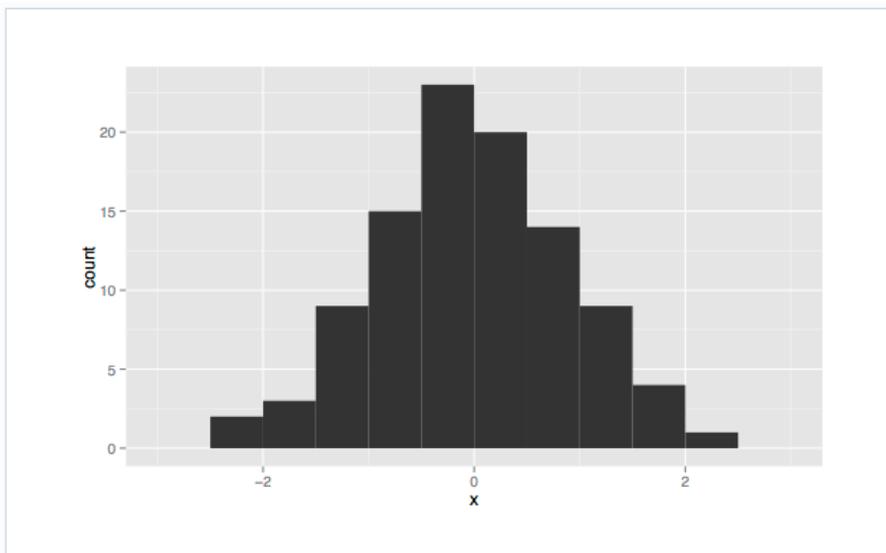
A análise do diagrama de causa-e-efeito é uma ferramenta muito poderosa, uma vez que for feita de maneira detalhada pode servir como um eficiente auxiliar para localizar e reparar defeitos e como uma experiência de grupo que leva as pessoas envolvidas a focarem no problema ao invés de atribuição de culpa. (Montgomery, 2017).

Muitas ferramentas migraram de outras ciências para o controle de qualidade, os histogramas são gráficos utilizados na estatística para apresentação de dados fazendo com que as informações sejam facilmente visualizadas e compreendidas para uma melhor tomada de decisão. Em conformidade com (Paladini, et al., 2012, p. 368) Os histogramas permitem identificar o padrão básico da população que representam, identifica de onde os dados foram extraídos e geram uma aproximação interessante da curva de frequência que caracteriza esses dados.

O histograma, exemplificado na figura 5 pode ser essencial na análise de um processo, (Montgomery, 2017, p. 428) diz que devemos dispor de pelo menos 100

observações para que o histograma seja moderadamente estável, a fim de obtermos uma estimativa razoavelmente confiável do processo. Utilizando esse gráfico de barras que apontam informações necessárias para visualizar a distribuição de dados e localização do valor central de tal distribuição, pode ser realizado comparações entre os histogramas e os limites de classificação que, permite identificar a tomada de decisões para diminuir a variação no processo.

Figura 5 Exemplo Histograma



Fonte: Alura, 2023

Outro gráfico que consiste em um gráfico de barras, conhecido por relação 80/20, em que 80% dos problemas são referentes a 20% das causas o gráfico de Pareto é uma maneira de dividir grandes problemas em menores e resolvê-los se torna mais fácil e atingível, tendo a capacidade de identificar os elementos críticos e os elementos menos importantes de um processo, apontando que os principais defeitos e problemas produtivos podem ser derivados de um número de causas pequeno.

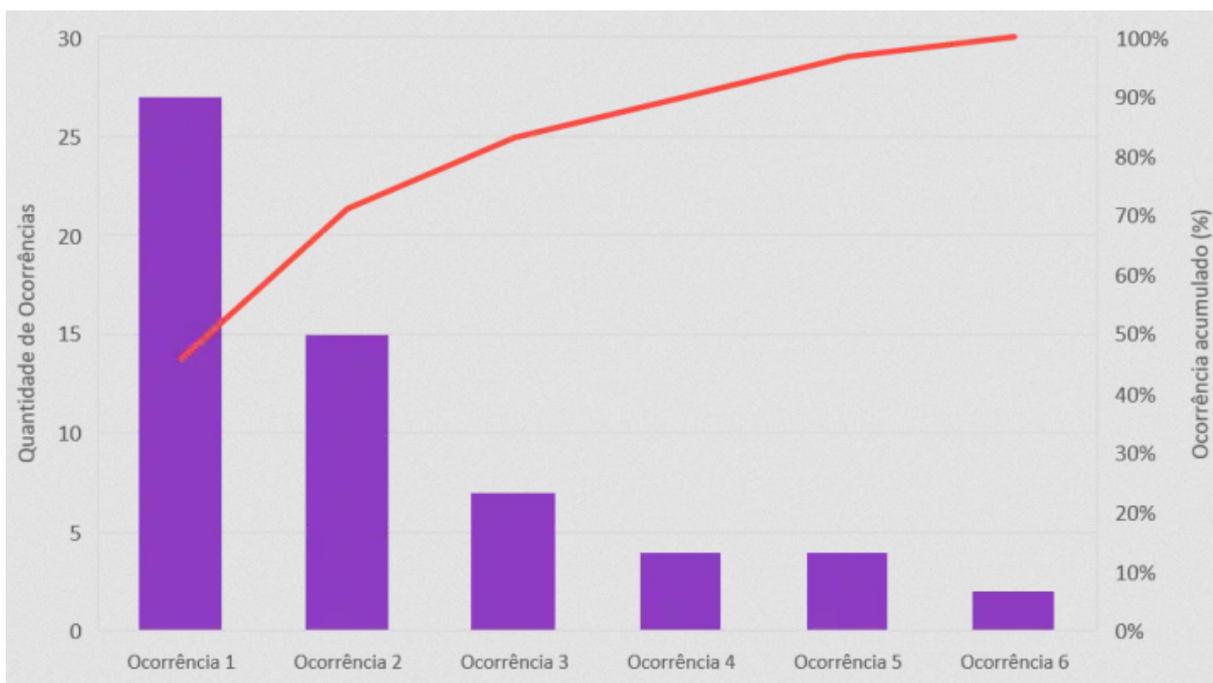
De acordo com (Paladini, et al., 2012, p. 362) o princípio do gráfico de Pareto pode ser expresso de várias formas:

Alguns consumidores concentram a maior parte da demanda.

- Algumas causas geram a maior parte dos defeitos.
- Alguns defeitos são responsáveis pela maioria das reclamações.
- Alguns equipamentos determinam a maioria das quebras e paradas.

- Algumas operações envolvem a maior parte das falhas.
- Alguns funcionários respondem pela grande maioria das sugestões de melhoria.
- Alguns produtos determinam a maioria das receitas.
- Alguns materiais são responsáveis pela maior parcela dos custos

Figura 6 Exemplo gráfico de Pareto



Fonte: Zeev, 2023

2.4.2 CLASSIFICAÇÃO DE TECIDOS NA TECELAGEM

De acordo com (Vieira, 1988, p. 218) a inspeção é o processo de medida, exame, teste ou verificação da unidade do produto, obedecendo a normas pré-estabelecidas.

Entende como unidade de produto o item submetido à inspeção para determinar sua quantidade ou classificação, (Vieira, 1988) diz que a inspeção pode ser feita das seguintes maneiras.

Inspeção por atributos, que se refere a unidade de produto é classificada como não defeituosa ou defeituosa, com base em uma exigência pré-determinada. Inspeção por variáveis acontece quando é observado as grandezas que assumem valores em escala contínua por exemplo resistência de um fio, peso/m² de um tecido etc. Na inspeção total ou inspeção 100% do lote, é classificado todas as peças

contidas no lote e evidentemente ela só pode ser realizada quando os ensaios realizados não são destrutivos esse tipo de inspeção ocorre quando existe a necessidade de que nenhuma unidade contida no lote seja defeituosa, por ser muito trabalhosa a sua aplicação, sempre que possível é combinada com outro tipo de inspeção ou substituída como por exemplo pela inspeção por amostragem. Quando a inspeção é realizada utilizando uma coleção de unidades retiradas ao acaso do lote é feita a inspeção por amostragem, qual obtém a vantagem de ser mais acessível do que a inspeção total e permite ainda uma observação minuciosa do produto.

É afirmado por (Vieira, 1988, p. 218) eu muitos confeccionistas, inclusive os de maior porte, inspecionam o tecido somente na mesa de corte. Isso faz com que gere atrasos na produção enquanto a peça não for avaliada, quando um fabricante tem o hábito de encaminhar peças sem defeitos para o confeccionista, é de passível compreensão que o confeccionista pode esperar para fazer a inspeção do tecido na operação de infestamento já que raramente são encontrados defeitos nesse risco assumido, no entanto deve-se obedecer a um programa de inspeção por amostragem. Esse programa de inspeção pode levar em consideração a confiabilidade que se tem no fornecedor, quanto maior o grau de confiança, menor será o percentual de peças destinadas à inspeção.

Cada remessa de tecido ou lote produzido é retirado amostras para os ensaios de laboratórios na máquina revisadora de tecidos, a peça será analisada para fins de identificação, marcação e classificação de defeitos, sua largura útil e a quantidade de defeitos.

Figura 7 Máquina revisadora de tecidos



Fonte: Omatex, 2023

Como pode ser observado na figura 7 as máquinas revisoras costumam ter de forma resumida um eixo para receber o rolo de tecido que vai ser inspecionado, tela luminosa ou não, para que seja visível as ocorrências ao desenrolar do tecido, outro eixo para que o tecido já revisado enrole, um motor de avanço, parada e retrocesso do tecido, em algumas máquinas pode ter o ajuste eletrônico para alinhamento das orelas. Conforme (Vieira, 1988) outras máquinas podem dispor de dispositivos automáticos de carga e descarga, eletrônicos para mensuração de cor.

(Vieira, 1988, p. 222) diz que seja a máquina mais ou menos complexa, necessário se torna que o elemento humano que com ela vai lidar apresente condições físicas mais ou menos desenvolvidas. Ainda conforme (Vieira, 1988, p. 224) com o exame visual de defeitos, são tomadas medidas de largura no início em vários pontos intermediários e no final da peça o que se faz acompanhar a medida de comprimento.

Os defeitos encontrados nas peças são mapeados, tal mapeamento pode ser feito marcado nas orelas, através de cartões, fitas gomadas ou fios coloridos juntamente com uma ficha de controle utilizando sua metragem, ou através de sistemas computacionais quais os defeitos são inseridos manualmente pelo operador da máquina, a distribuição de defeitos pela metragem da peça atribui a ela um número

de pontos, essa pontuação irá determinar a classificação da peça como de primeira ou de segunda qualidade. Um sistema objetivo de classificação de tecidos precisa estabelecer os defeitos que são significativos, em outras palavras aqueles que realmente impactam diminuindo a qualidade de um tecido, manter os defeitos agrupados conforme sua importância, traduzir de maneira numérica (utilizando sistema de pontuação) a relação de importância entre os grupos de defeito, determinar a pontuação de aceitação e rejeição para uma determinada peça de tecido dentro do sistema adotado e coerente com os níveis de qualidade exigidos para cada classificação de tecido esse critério por auxiliar na identificação de peças de primeira e de segunda qualidade.

De acordo com (Vieira, 1988) para determinar valores relativos aos defeitos, deve ser levado em consideração os seguintes fatores. O tamanho da área afetada pelo defeito, a intensidade do defeito, ou seja se o defeito será visto com mais ou menos esforço pois um defeito pequeno e muito contrastante pode ser tão visível quanto um defeito grande e a posição do defeito também tem um peso grande no valor atribuído a pontuação em termos de classificação, por exemplo um defeito na trama de orela a orela, tem o mesmo valor de um defeito de 2cm de largura de orela a orela, pois será necessário remover ambos do tecido fazendo com que seja feito um retalho, se não podem atingir mais de uma peça na confecção.

Deve ser estabelecido pela classificação de tecidos um número máximo de pontos atribuídos por metro de tecido, assim quando muitos ou alguns defeitos de grande intensidade se encontrarem em uma posição do tecido, não fará com que necessariamente a peça seja inutilizada o mais provável a ser realizado é que seja efetuado um corte retirando a porção defeituosa.

O sistema de 4 pontos foi criado em 1959 pela American Society for Quality Control – A.S.Q.C (Sociedade Americana de Controle de Qualidade) propôs uma norma de 4 pontos para a determinar a qualidade dos tecidos dentro desse sistema não pode ser atribuído mais de 4 pontos de defeito por metro, para a base de cálculo é utilizado 82 m² ou 100 yd² o nível de aceitação dos defeitos podem ser variados conforme acordos previamente estipulados pelo vendedor e comprador, a Figura 8 representa os pontos recomendados para a proporção do defeito.

Figura 8 Tabela de pontuação sistema de 4 pontos

Valores para o Sistema de 4 pontos	
7,5 cm ou menos.....	1 ponto
Maior que 7,5 cm e menor que 15 cm.....	2 pontos
Maior que 15 cm e menor que 23 cm.....	3 pontos
Acima de 23 cm.....	4 pontos

Conforme (Vieira, 1988), de um modo geral, não são aceitos em um tecido de primeira qualidade mais do que 40 pontos por 100 jardas quadradas, ele também reforça que o sistema classifica os defeitos em três categorias:

- Defeitos auto descritivos (pregas, rugas, vincos e dobras)
- Defeitos definidos (fios soltos)
- Defeitos excepcionais (tramas onduladas)

A Associação Brasileira de Normas Técnicas – Norma Brasileira 13378 (ABNT NBR 13378) tecidos planos defeitos terminologia específica diferentes tipos de defeitos que podem ocorrer durante diferentes processos de produção de tecidos planos. Sendo classificados em categorias, como defeitos de fiação, defeitos tecelagem, defeito de tramas entre outros. Os defeitos de fiação estão relacionados ao estágio inicial da produção têxtil, envolvendo a criação dos fios que serão posteriormente utilizados para tecer o tecido.

Fio grosso de urdume e fio grosso de trama, o fio possui um diâmetro maior do que o especificado, devido a título errado, irregularidade na retorção, alimentação dupla do pavio entre outros, conforme apresenta a figura 9.

Figura 9 Fio Grosso urdume



Fonte: Neves, 2012

Trama misturada, uma barra diferente no tecido devido à mistura de tramas, geralmente causada por trocas de espulas, bobinas ou cones, conforme apresenta a figura 10.

Figura 10 Trama misturada



Fonte: Neves, 2012

Ao passar para o estágio de tecelagem, outros defeitos podem surgir afetando a estrutura do tecido ainda baseado na ABNT NBR 13378 alguns defeitos de tecido que ocorrem na tecelagem.

Bolinha de engomagem, sujeiras e fibras que se aglomeram durante a engomagem e ficam presas nos fios de urdume, conforme apresenta a figura 11.

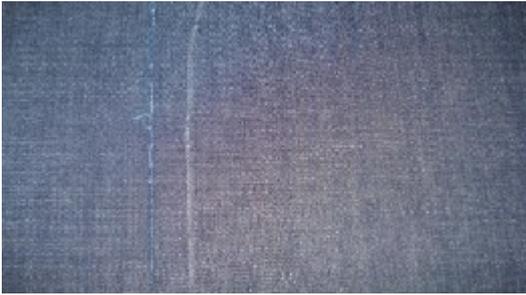
Figura 11 Bolinha de engomagem



Fonte: Neves, 2012

Urdume frouxo, fios de urdume soltos no tear, causados por diversos fatores como problemas na urdideira ou engomadeira, conforme apresenta a figura 12.

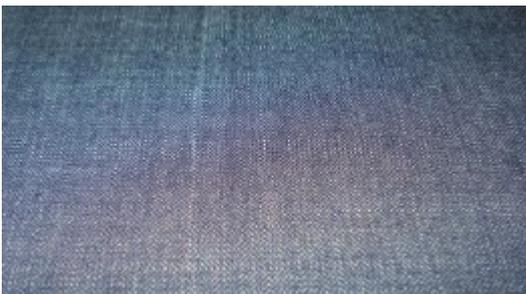
Figura 12 Urdume frouxo



Fonte: Neves, 2012

Urdume esticado, fios de urdume submetidos a tensão excessiva, resultando em fios brancos e brilhantes, conforme apresenta a figura 13.

Figura 13 Urdume esticado



Fonte: Neves, 2012

Urdume duplo, fios de urdume aderidos uns aos outros devido ao processo de engomagem, resultando em uma mudança no aspecto visual, conforme apresenta a figura 14.

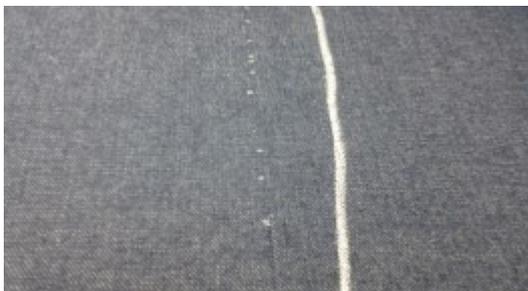
Figura 14 Urdume duplo



Fonte: Neves, 2012

Canastra, os fios de trama estão sobre os fios de urdume, ao invés de estarem entrelaçados, conforme apresenta a figura 15.

Figura 15 Canastra



Fonte: Neves, 2012

Nó de urdume, saliências no urdume devido a emendas malfeitas durante vários processos, conforme apresenta a figura 16.

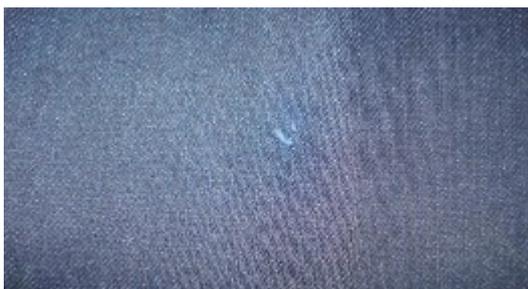
Figura 16 Nó de urdume



Fonte: Neves, 2012

Ruptura de urdume, rompimento dos fios de urdume no meio, deixando pontas soltas, conforme apresenta a figura 17.

Figura 17 Ruptura de urdume



Fonte: Neves, 2012

Os defeitos de trama ocorrem durante a inserção dos fios de trama no tecido afetando sua uniformidade e aparência, com base na ABNT NBR 13378.

Trama misturada, fios de trama com titulações ou números de cabos diferentes misturados, resultando em faixas no sentido de trama, conforme apresenta a figura 18.

Figura 18 Trama misturada



Fonte: Neves, 2012

Trama frouxa, fios de trama que não recebem a tensão necessária, resultando em fios frouxos no tecido, conforme apresenta a figura 19.

Figura 19 Trama frouxa



Fonte: Neves, 2012

Estripada, fios embaraçados na mesma cala de trama devido a problemas na estripagem do cone ou na troca de espulas, conforme apresenta a figura 20.

Figura 20 Estripada



Fonte: Neves, 2012

Trama dupla, duas ou mais tramas inseridas na mesma cala, rompendo a estrutura do tecido, conforme apresenta a figura 21.

Figura 21 Trama dupla



Fonte: Neves, 2012

Reintroduzida, fios de trama inseridos parcialmente a mais na cala, não abrangendo toda a largura do tecido, conforme apresenta a figura 22.

Figura 22 Reintroduzida



Fonte: Neves, 2012

Trama curta, inserção parcial de fios de trama, resultando em trama eu não cobre toda a espessura do tecido, conforme apresenta a figura 23.

Figura 23 Trama curta



Fonte: Neves, 2012

Ruptura de trama, rompimento no meio do fio de trama, deixando pontas soltas, conforme apresenta a figura 24.

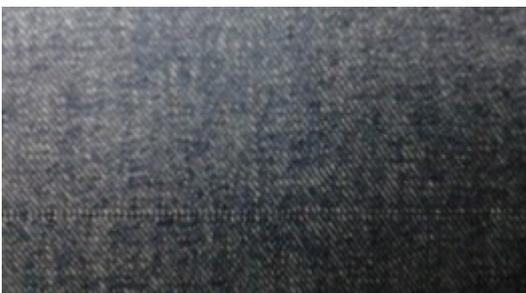
Figura 24 Ruptura de trama



Fonte: Neves, 2012

Falta de trama, ausência de fios de trama em toda a espessura do tecido devido à quebra na armação, conforme apresenta a figura 25.

Figura 25 Falta de trama



Fonte: Neves, 2012

Raleira, barramento na trama causado por diminuição do número de batidas.

Marca de parada de tear, lista estreita causada por parada do tear, afetando a densidade do tecido, conforme apresenta a figura 26.

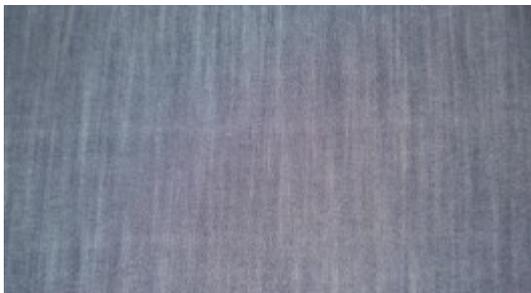
Figura 26 Raleira e parada de tear



Fonte: Neves, 2012

Variação de batidas, listras de diferentes espessuras no tecido devido à variação da densidade das batidas da trama, conforme apresenta a figura 27.

Figura 27 Variação de batidas



Fonte: Neves, 2012

Pelotas, acúmulo de fibrilas e sujeiras ao atrito do fio durante a construção do tecido, conforme apresenta a figura 28.

Figura 28 Pelotas



Fonte: Neves, 2012

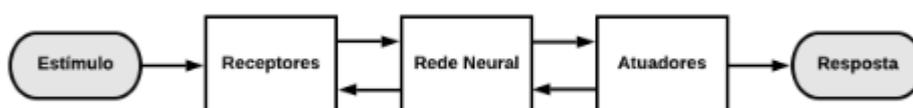
3 INTELIGIÊNCIA ARTIFICIAL

Considerando a natureza das informações envolvidas, a aplicação de métodos de anomalias é uma parte crucial deste estudo. Enquanto o processo de revisão de tecidos planos tradicionalmente requer a intervenção de um operador humano para inspecionar e classificar visualmente o tecido, a detecção de anomalias pode ser realizada de forma automatizada através do uso de técnicas estatísticas combinadas com inteligência artificial.

Neste contexto, a inteligência artificial tem o potencial de desempenhar um papel fundamental. Utilizando algoritmos e aprendizado de máquina, a inteligência artificial pode analisar as informações coletadas a partir de imagens do tecido. Essa análise visa identificar e classificar tecidos com ou sem defeitos, proporcionando uma abordagem mais eficiente e precisa para a detecção de anomalias no processo de revisão de tecidos planos.

A rede neural tem o objetivo de fazer com que computadores sejam capazes de reproduzir o desempenho do cérebro humano de maneira mais eficaz, sendo apta para identificar padrões, retirar regularidades e identificar semelhanças em um conjunto de dados visivelmente incoerente. A figura 29 esquematiza o sistema nervoso humano, que serve como base para a construção de algoritmos de redes neurais. Os receptores convertem estímulos do corpo ou do ambiente externo em impulsos elétricos, transmitindo informações para a rede neural (cérebro). Os atuadores transformam os impulsos elétricos gerados pela rede neural em respostas discerníveis, que são as saídas do sistema, esse sistema possui duas direções de transmissão de sinais: da esquerda para a direita, representando a transmissão direta de informações pelo sistema e da direita para esquerda, indicando a realimentação do sistema (Crus, 2019).

Figura 29 Esquema em blocos de rede neural



Fonte: Crus, 2019

Conforme (Crus, 2019) a rede neural é um meio de inteligência artificial capaz de processar informações de maneira maciça, paralela e distribuída. Sendo formada por unidades de tratamento simples que dispõem da capacidade de guardar o conhecimento obtido experimentalmente e transformá-lo em conhecimento para a aplicação. Tal conhecimento é alcançado através de um processo de aprendizagem e por forças de conexões entre neurônios, também conhecidos como pesos sinápticos usados para armazenar o conhecimento. A aplicação dessa técnica em problemas reais resulta em benefícios, fazendo com que a rede neural extraia todo o potencial computacional através de sua estrutura e habilidade de aprendizagem possibilitando a solução de problemas difíceis. Segundo (Crus, 2019) deve fragmentar o problema e designar a rede neural um subconjunto de atividades para que seja possível a solução, o uso de redes neurais oferece as principais características e capacidades fundamentais:

Mapeamento de entrada e saída, sendo capazes de criar relações complexas entre os dados de entrada e as saídas desejadas, permitindo que aprendam a mapear padrões e informações de entrada para produzir resultados significativos.

Adaptabilidade, a sua capacidade de se ajustar e aprender com os dados ao longo do tempo, o que as torna adequadas para lidar com problemas complexos e em constante mudança.

Tolerância a falhas, as redes neurais podem ser robustas em relação a perturbações ou ruídos nos dados, o que significa que ainda podem produzir resultados úteis mesmo quando os dados não estão perfeitos ou são incompletos.

Dessa maneira é possível definir a rede neural como um conjunto de inúmeras unidades interconectadas, essas unidades são chamadas de neurônios artificiais, aonde cada um utiliza uma pequena parcela de memória local. Esse neurônio é fundamental para o funcionamento de uma rede neural.

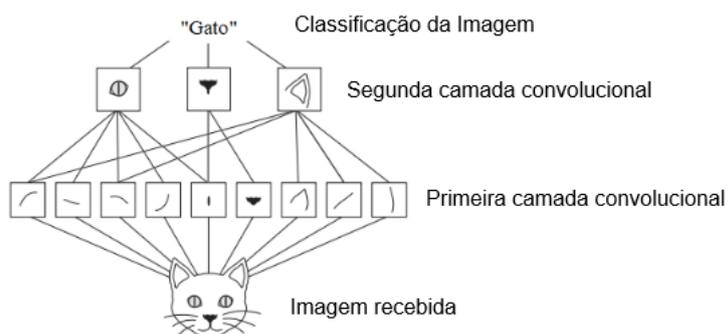
De acordo com (Silva, 2022) de uma maneira geral, as redes neurais podem ser classificadas em duas categorias, direta ou recorrente. A primeira conhecida como *feedforward*, os sinais ou informações da rede caminham em apenas um sentido, seguindo das entradas até as saídas. As redes convolucionais (*convnets*), são frequentemente utilizadas para classificação e reconhecimento de imagens, essas se encaixam na categoria das redes neurais diretas, as *convnets* são caracterizadas pela aplicação da convolução, uma operação matemática em pelo menos uma de suas

camadas. Enquanto nas recorrentes as informações navegam pela rede nos dois sentidos, onde pode ocorrer loops durante o processo.

As redes convolucionais tem por objetivo algumas aplicações como detecção de objetos, reconhecimento facial, processamento de fala entre outros. (Silva, 2022) destaca que as *convnets* apresenta ótimos resultados ao serem utilizadas no ramo da computação visual, qual apresenta uma estrutura básica com duas camadas, convolucional e *pooling*.

A camada convolucional é responsável por realizar a operação de convolução. Considerando que a *convnet* é treinada para classificar imagens, conforme (Silva, 2022) a convolução permite que o programa reconheça e aprenda padrões locais, a partir de uma imagem recebida como entrada no modelo. A imagem será interpretada pelo sistema de baixo para cima, assim que recebe a imagem o programa irá aplicar a primeira camada convolucional, essa primeira camada possibilita o reconhecimento de pequenos padrões e bordas a partir da imagem, em seguida é aplicado uma segunda camada convolucional qual torna possível reconhecer padrões ainda maiores. Finalmente após as duas camadas convolucionais anteriores é possível reconhecer padrões de forma hierárquica e a rede neural consegue apontar qual a classificação da imagem recebida a figura 30 representa essa operação. De acordo com (Silva, 2022) os padrões aprendidos pela *convnet* são invariantes por translação, ou seja, se uma rede convolucional aprendeu um padrão no canto superior esquerdo de uma imagem, ela poderá reconhecer esse padrão em outro lugar da imagem, como no canto superior direito por exemplo, isso fará com que o modelo aprenda de forma mais rápida, processando imagens com mais eficiência.

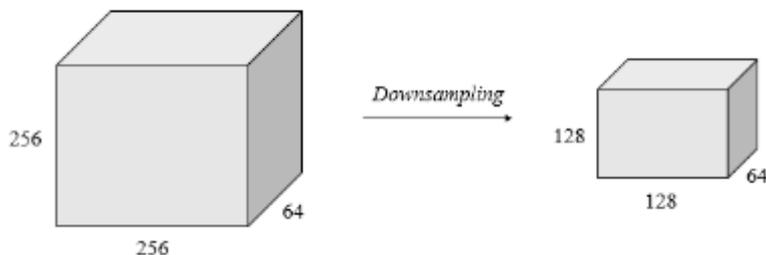
Figura 30 Exemplo de operações convolucionais



É importante destacar a funcionabilidade dos filtros e mapas de *features* nas operações convolucionais, os filtros são responsáveis por capturar características de *input* (Entrada), após é gerado um mapa de *features* como *output* (saída). Assim esse processo se repete conforme a quantidade de camadas convolucionais presentes no sistema.

Conforme (Silva, 2022), a camada pooling, por sua vez, é responsável por realizar a operação de *downsampling*, qual conceito está associado a compressão ou redução. Essa operação faz com que as representações da rede convolucional sejam reduzidas, tornando o modelo menor e mais manipulável. A figura 31 ilustra o *downsampling* em uma camada do tipo *pooling* onde é possível observar a esquerda um mapa de ativação com dimensões de 256 x 256 x 64, quais são, comprimento, largura e profundidade, respectivamente. É possível observar que, a partir da compressão, as dimensões são reduzidas para 128 x 128, porém a profundidade se mantém com 64.

Figura 31 Exemplo de operação da camada *pooling*

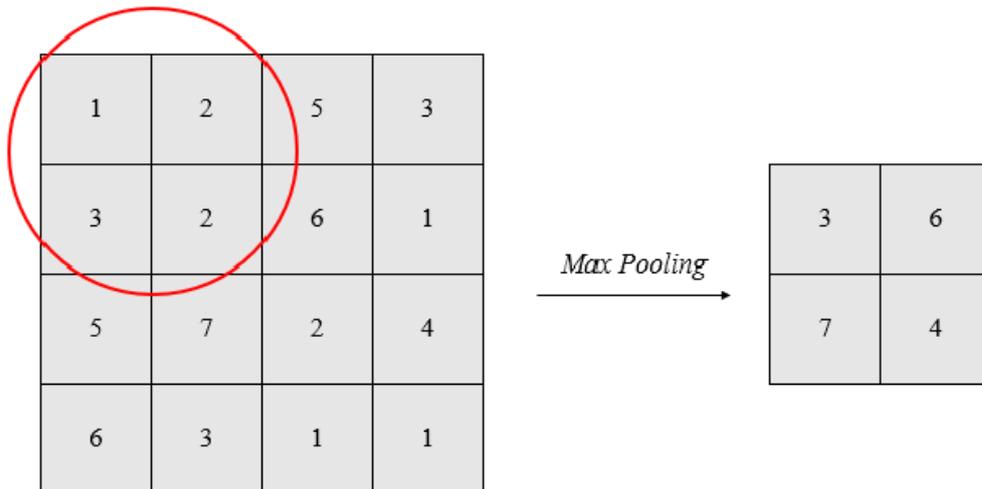


Fonte: Silva, 2022

(Silva, 2022) também diz que para aplicar o *pooling* podemos utilizar o *max pooling* ou o *average pooling*, para atingir o *downsampling*, a primeira opção tende a funcionar melhor do que a segunda. Dessa forma a figura 32 observa como a operação de *max pooling* funciona. Esse exemplo é aplicado um filtro 2x2 com um *stride* (passo) de 2. Assim o quadrado da esquerda será dividido em 4 quadrados menores, conforme a demarcação pelo círculo vermelho, para cada um desses quadrados, será eligido o maior valor qual substituirá todos os outros. No quadrado demarcado pelo círculo o maior valor é o 3, sendo assim após o *max pooling*, os quadrados serão substituídos pelo que possui o maior valor. Também é importante

perceber, após a operação do *max pooling*, como a dimensão do quadrado diminuiu de 4x4 para 2x2, visto que esse é o objetivo da operação.

Figura 32 Aplicação de max pooling para atingir downsampling



Fonte: Silva, 2022

3.1 FERRAMENTAS PARA APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL

As redes neurais podem ser aplicadas em diferentes setores da sociedade alguns exemplos notáveis desse campo de estudo são: o Google que utiliza redes neurais atribuindo rótulos e palavras-chave a imagens, a Microsoft desenvolveu redes neurais responsáveis de converter discursos em diferentes idiomas, pesquisadores da Suécia utilizaram as redes para identificar combinações entre doadores e receptores de transplantes de coração fazendo com que aumentasse a taxa de sobrevivência dos receptores. A manufatura também tem destaque no suporte com redes neurais, como inspeções visuais de qualidade, controle de processos, modelagem dinâmica de processos químicos, análise de dados entre outros.

Python é uma das linguagens de programação mais utilizadas na área da ciência de dados atualmente, com conhecimentos básicos na linguagem é possível realizar pesquisas avançadas em inteligência artificial e aprendizagem profunda (do inglês *deep learning*), graças a *frameworks* e bibliotecas que facilitam na hora de escrever os códigos.

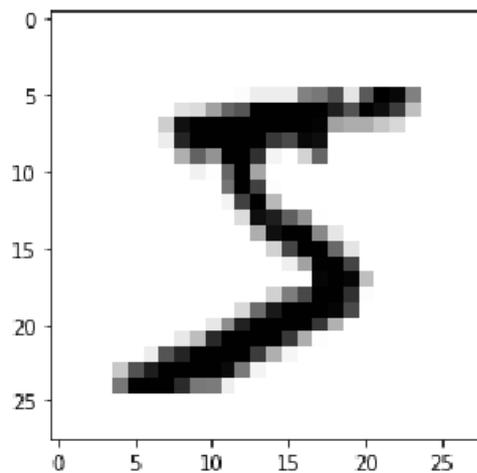
(Silva, 2022) destaca duas bibliotecas gratuitas em Python, quais são bastante utilizadas por profissionais de dados e estatísticos NumPy e Pandas. NumPy tem como objetivo realizar operações matemáticas e estatísticas com arranjos multidimensionais e matrizes, ele também é extremamente eficiente com grande volume de dados. O Pandas tem como foco criar e manipular estruturas de dados, para realizar análises e operações, uma das formas de armazenar dados com o Pandas é por meio de um *DataFrame*, um arranjo bidimensional estruturado no formato de tabela contendo linhas e colunas.

TensorFlow é outra ferramenta que pode ser utilizada na linguagem Python para facilitar pesquisas e trabalhos que (Silva, 2022) destaca, essa ferramenta consiste em um *framework* do Google lançado em 2015, seu objetivo principal é simplificar a manipulação de tensores e permitir a implementação de novos modelos de *deep learning*, um tensor é um vetor ou uma matriz de “n” dimensões, possuindo basicamente três propriedades nome, formato e tipo do dado. O TensorFlow foi construído para que os códigos pudessem ser executados em GPUs (unidades de processamento gráficos), assim é possível o processamento em paralelo, trazendo velocidade computacional.

3.2 IMPLEMENTAÇÃO DA INTELIGÊNCIA ARTIFICIAL

Para exemplificar a implementação de uma rede neural convolucional para classificar imagens, será utilizado imagens de dígitos manuscritos, quais compõem a base de dados MNIST. O conjunto de dados do MNIST estão disponíveis 60000 imagens no *dataset* de treino e 10000 no de teste. De acordo com (Silva, 2022) cada imagem apresenta uma resolução de 28 pixels, na escala de cor cinza, possuindo um rótulo correspondendo, em outras palavras a imagens do número 5 possui o rótulo 5 associado a ela. Os elementos de sua base são estruturados no formato de *array* e cada pixel assume valor entre 0 e 255, utilizando o Matplotlib (biblioteca Python) é possível visualizar esse dado em formato de imagem. Na figura 33 é possível observar o elemento correspondente ao número 5.

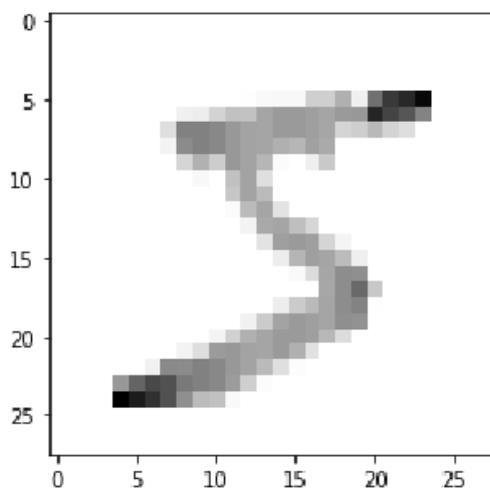
Figura 33 Imagem do elemento 5 da base MNIST sem normalização



Fonte: Silva, 2022

A seguir o processo de normalização é aplicado nos dados, para que os valores dos pixels fiquem entre 0 e 1. Conforme (Silva, 2022) a normalização é uma boa prática que diminui o intervalo dos dados, já que ter valores de pixels entre 0 e 255 pode dificultar o aprendizado da rede neural, sendo assim com a normalização aplicada é possível visualizar na figura 34 que a imagem do número 5 o tom de cinza muda em algumas partes do número, mas ainda é possível perceber de forma clara que se trata de um 5.

Figura 34 Imagem do elemento 5 da base MNIST com normalização

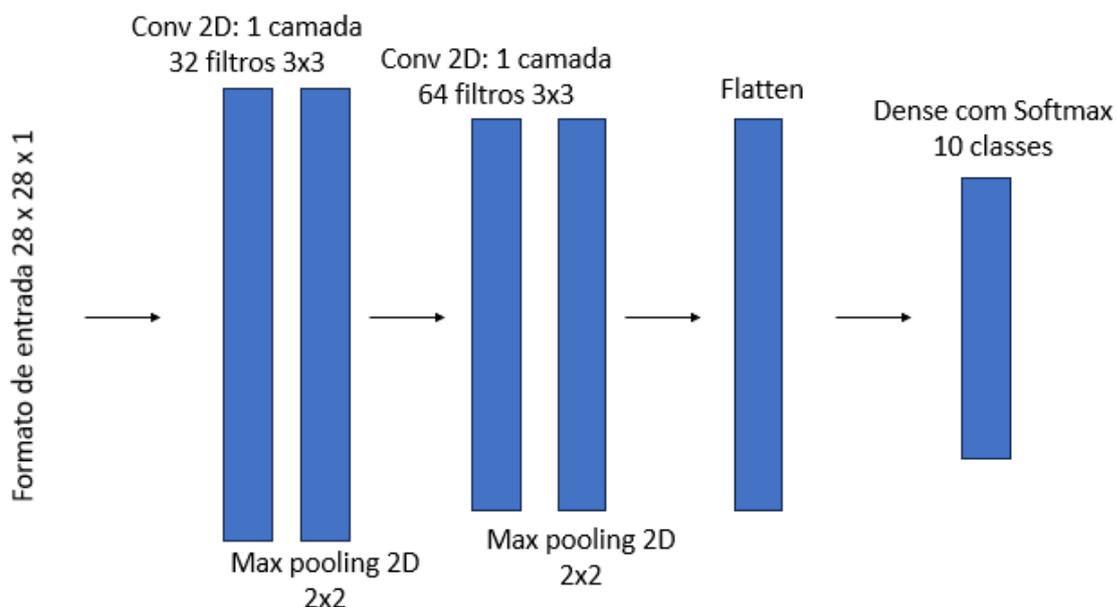


Fonte: Silva, 2022

Após a visualização e normalização dos dados é necessário adicionar a dimensão certa de canal às imagens, para que os dados estejam no formato adequado para a rede convolucional (Silva, 2022). Dessa forma, os valores de cada uma das imagens da base MNIST são 28 na altura, 28 na largura e 1 no canal, já que está sendo utilizado escala de cores de cinza. Com essas manipulações iniciais finalizadas é possível criar a *convnet*.

A figura 35 representa o modelo utilizado para a classificação. De acordo com (Silva, 2022) é possível observar que a rede possui 2 camadas convolucionais, 2 para a operação de *max pooling* e a última destinada para a classificação, com 10 neurônios, qual foi aplicado a função Softmax. A função Softmax transforma um conjunto de valores de entrada em uma distribuição de probabilidade, o que significa que a soma de todas as saídas da função é igual a 1.

Figura 35 Rede neural convolucional para classificar imagens do MNIST



Fonte: Adaptado de Silva, 2022

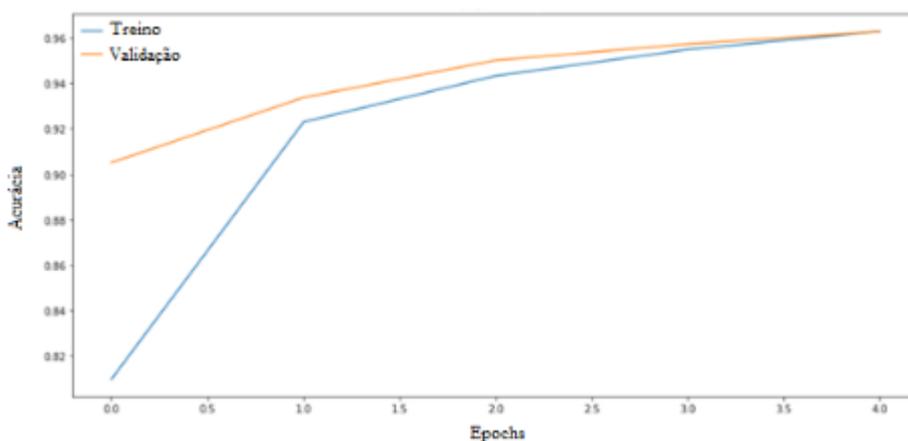
Na sequência, é possível observar na figura 36 alguns parâmetros definidos, conforme (Silva, 2022) 30% dos dados de treino estão reservados para validação, ou seja, 42000 imagens são para o treinamento e as outras 18000 são para validação além disso, apenas 5 *epochs* (o conjunto de dados passado uma vez na rede neural é denominado de *epoch*) foram definidas para o treinamento da rede.

Figura 36 Parâmetros para classificação no MNIST

Otimizador	Adam
Taxa de aprendizado	0,0001
Perda	Sparse categorical cross entropy
Métricas	Acurácia
Tamanho do lote	32
Epochs	5
Porcentagem para validação	30%

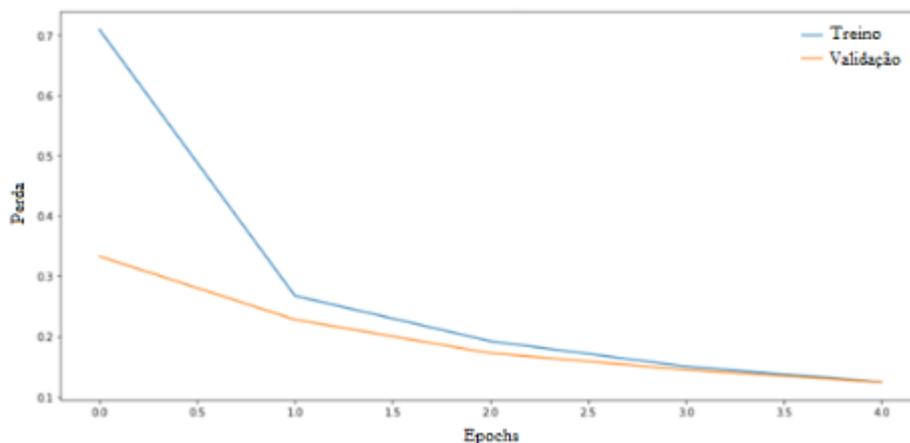
Fonte: Silva, 2022

Os resultados a seguir foram obtidos por (Silva, 2022) utilizando a unidade de processamento gráfico, GPU, como tipo de processador para analisar a acurácia na figura 37. É possível perceber que o modelo atinge resultados positivos, aproximadamente 96% para treino e validação, nesse sentido na figura 38 vemos que a perda é minimizada nos dois conjuntos, que atingem valores próximos de 0,1. Com esses resultados das imagens destinadas para validação é possível constatar que o modelo generalizou de forma adequada.

Figura 37 Acurácia de *convnet* para classificar imagens de MNIST

Fonte: Silva, 2022

Figura 38 Perde de *convnet* para classificar imagens de MNIST



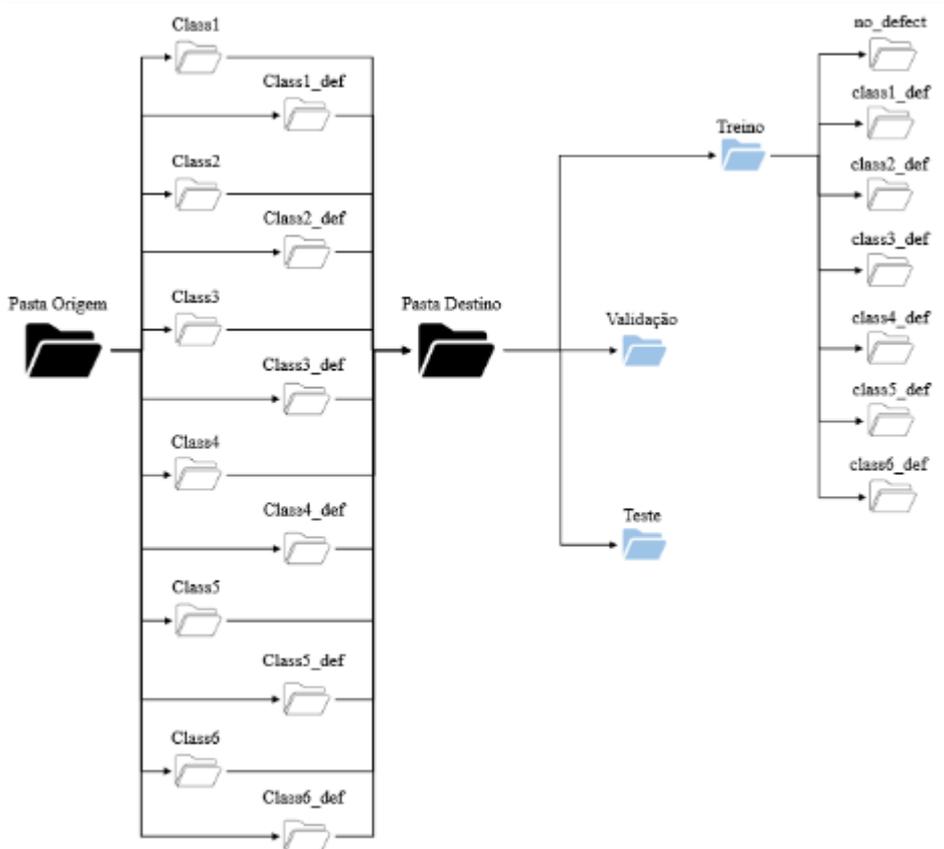
Fonte: Silva, 2022

De acordo com (Silva, 2022) a acurácia e perda a partir dos dados destinados para teste, foram de 96,63% e 0,11 respectivamente. Por fim, além da GPU foram utilizados dois tipos de processadores para treinar a *convnet* CPU (unidade de processamento central) e a TPU (unidade de processamento de tensor)

3.3 DETECÇÃO DE DEFEITOS COM INTELIGÊNCIA ARTIFICIAL

Utilizando o *dataset* da DAGM será possível classificar os defeitos em seis classes de tecidos. Conforme (Silva, 2022) para tal acontecimento é necessário utilizar uma estrutura de pastas. Na pasta destino são consideradas todas as tramas de tecidos, com e sem defeitos e cada arquivo deverá ser designado de acordo com a classe a qual pertence. A figura 39 apresenta a organização, as pastas compõem o diretório de treino, validação e teste. A pasta “no_defect” tem como função alocar todas as imagens sem defeitos e as outras pastas com os defeitos de pertencentes a determinada classe. Para fins de exemplificação o esquema ilustra somente dos subdiretórios da pasta treino para que a figura não fique confusa, pois os diretórios de validação e teste possuem a mesma estrutura demonstrada para o treino. Foi utilizado na pasta de treino 3864 imagens, sendo que 3360 são sem defeitos e 04 com defeito, 84 para cada classe, a pasta validação contém 166, 1440 sem defeito e 216 com defeito, 36 para cada classe. Por fim, a pasta de teste tem 1380 imagens sendo 1200 sem defeito e 180 com defeito, 30 para cada classe.

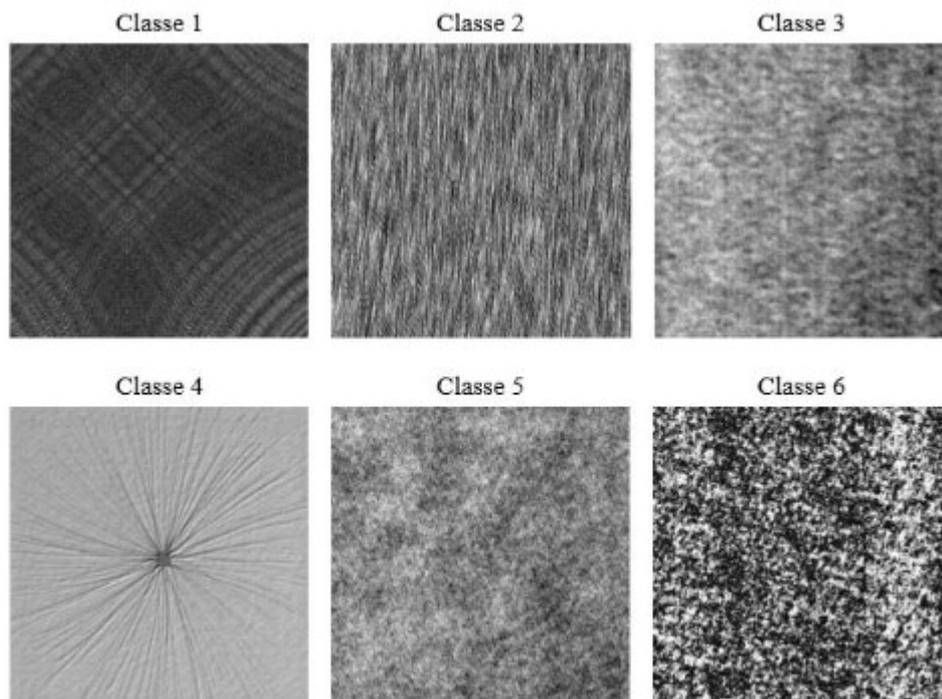
Figura 39 Organização de pastas



Fonte: Silva, 2022

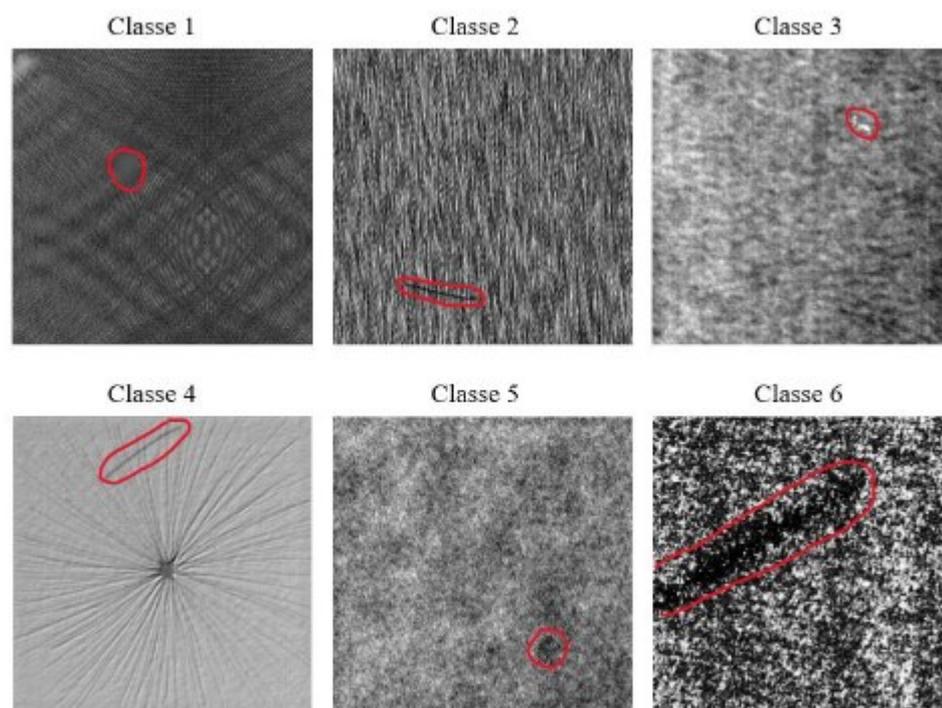
Para realizar o pré-processamento da imagem (Silva, 2022) transforma arquivos de imagens em tensores pré-processados, utilizando a VGG16 abreviação para “Grupo de Geometria Visual”, um grupo de pesquisadores da Universidade de Oxford, 16 representa a arquitetura da rede neural, qual é formada por 16 camadas, esse modelo ficou conhecido após alcançar 92% de acurácia no *ImageNet*, um conjunto de dados com mais de 14 milhões de imagens quais pertencem a 1000 classes diferentes. Além disso, as imagens do conjunto de dados contam originalmente com 512 pixels, foram transformadas para ficarem com altura e largura iguais a 244 na figura 40 encontra-se as imagens dos tecidos sem defeitos já na figura 41 é possível observar as imagens de tecidos com defeitos destacados com uma demarcação em vermelho.

Figura 40 Classes de tecidos sem defeitos



Fonte: Silva, 2022

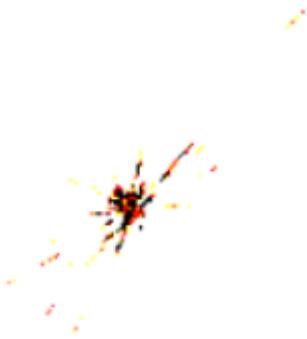
Figura 41 Classes de tecidos com defeitos



Fonte: Silva, 2022

Na figura 42 é possível observar um tecido sem defeito da classe 4 De acordo com (Silva, 2022), após aplicar a função de pré-processamento da VGG16 é nítido como o pré-processamento altera a imagem de forma significativa, dificultando identificar que a imagem se trata de um tecido da classe 4.

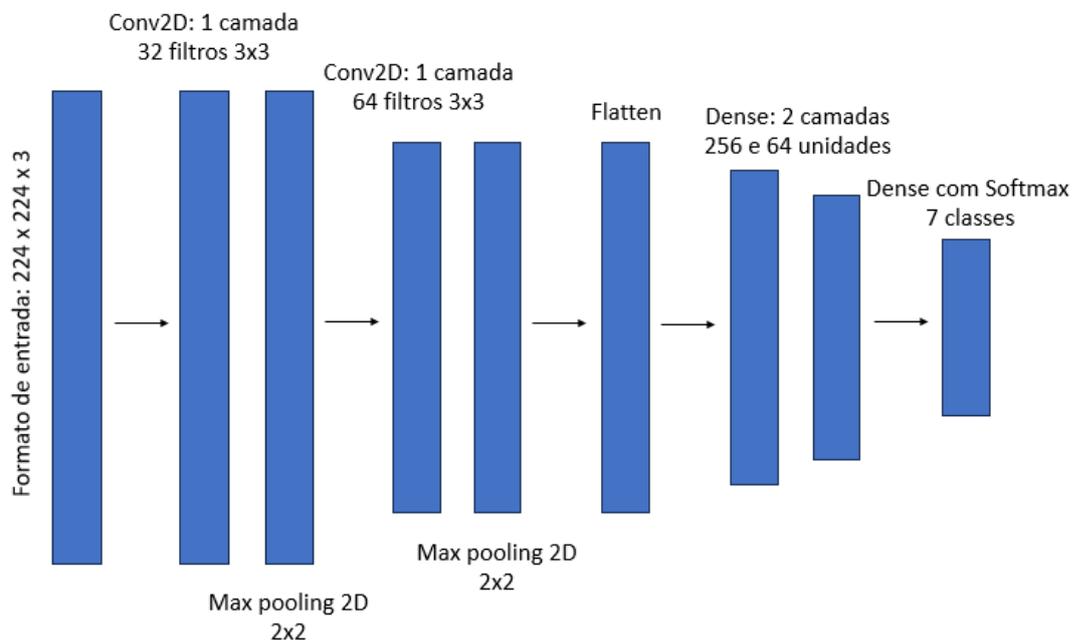
Figura 42 Tecido sem defeito da classe 4 após pré-processamento da VGG16



Fonte: Silva, 2022

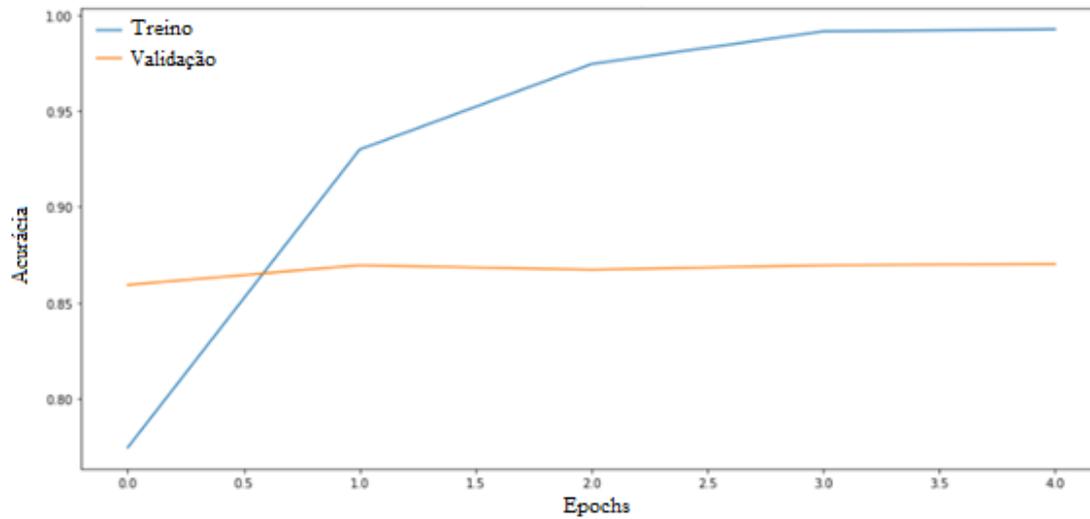
Na figura 43 foi adicionado uma camada do tipo *dense* com 256 unidades, essa alteração conforme (Silva, 2022) busca trazer mais profundidade à rede, na tentativa de obter mais resultados. A última camada do tipo *dense* possui 7 unidades, já que temos 7 classes, quais 6 são destinadas a imagens com defeitos e uma para imagens sem defeitos.

Figura 43 Rede neural convolucional para classificar tecidos

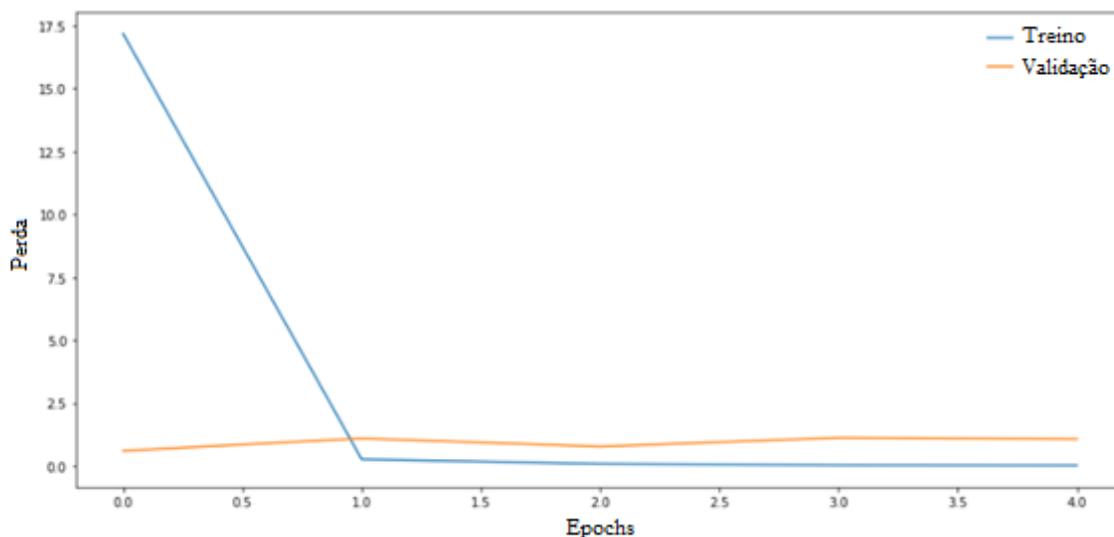


Fonte: Adaptado de Silva, 2022

Após 5 *epochs* (Silva, 2022) destaca que o tempo realizado para treinar a rede foi de 15 min e 24 segundos. A figura 44 mostra a acurácia para dados de validação e treino. Em treino a *convnet* chega em torno de 99% e para validação aproximadamente 87%. Enquanto a figura 45 é observado o gráfico da perda, os dados de treino apresentam valores de 0,02, enquanto os valores de validação chegam a cerca de 0,87.

Figura 44 Acurácia da *convnet* para classificar imagens de tecidos

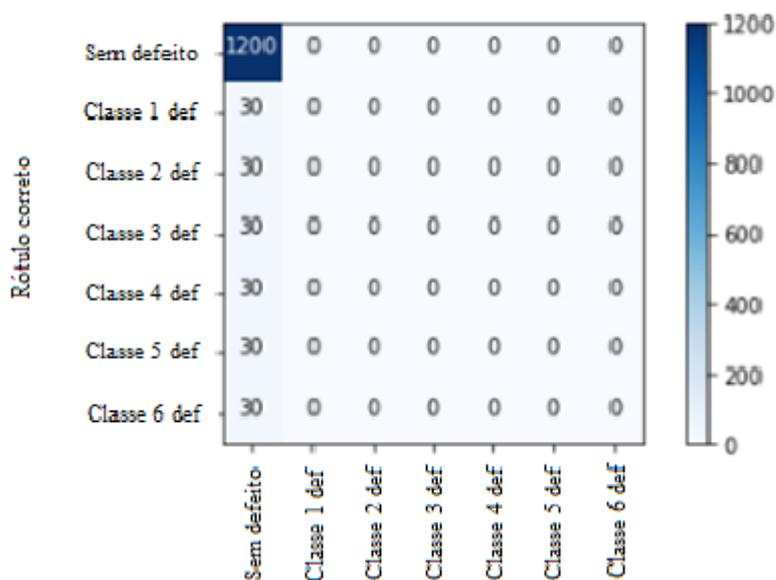
Fonte: Silva, 2022

Figura 45 Perda de *convnet* para classificar imagens de tecidos

Fonte: Silva, 2022

Ao analisar a figura 46, é possível observar que temos 1200 imagens sem defeito, o modelo acertou todas. (Silva, 2022) destaca que das 180 imagens sem defeito, a rede não classificou nenhuma corretamente. Dessa maneira é interpretável que de um aproveitamento geral de 86,96% a rede não consegue identificar nenhuma imagem com defeito, evidenciando a presença de muitos falsos negativos.

Figura 46 Matriz de confusão para classificação de tecidos



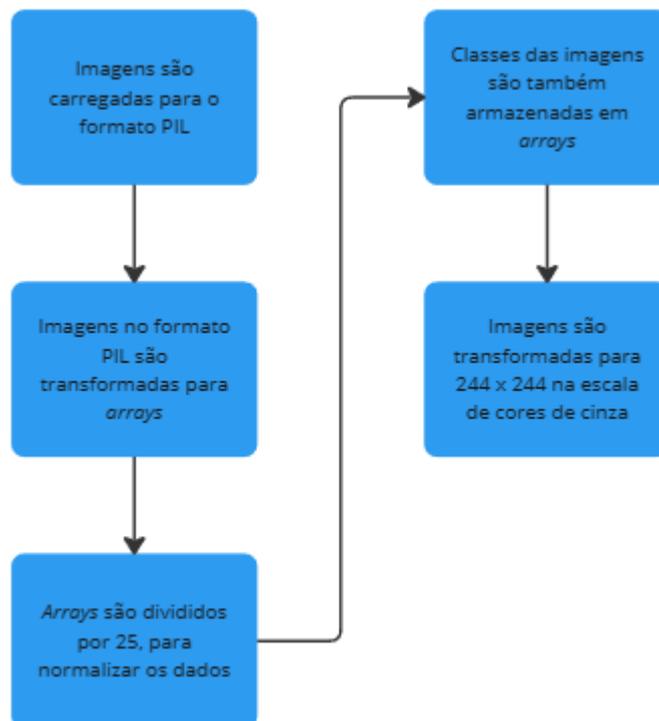
Fonte: Silva, 2022

É possível perceber a ocorrência de *overfitting*, um problema que ocorre quando o desempenho de uma rede neural piora com dados que não teve contato anteriormente quando comparado com sua performance a partir de dados de treinamento, como o objetivo principal do *machine learning* é alcançar bons resultados a partir de dados que o algoritmo não teve contato anteriormente o *overfitting* é um grande obstáculo para o desenvolvimento de boas redes neurais. A partir dos resultados obtidos (Silva, 2022) sugere melhorias para a rede neural. Dado a informação que o modelo não foi capaz de detectar os tecidos defeituosos, gerando muitos falsos negativos sendo necessário soluções para que o modelo possa diminuir os falsos negativos, elaborando modelos capazes de detectar os defeitos.

Conforme observado anteriormente na figura 42, o pré-processamento da VGG16 afeta a imagem, de tal maneira que não é possível identificar com facilidade se há ou não um defeito no tecido. Sendo assim a função é removida para ser utilizado funções disponíveis no TensorFlow "load_img" e "img_to_array". De acordo com (Silva, 2022) a função load_img é responsável por carregar imagens dos tecidos e convertê-las em formato PIL (*Python Image Libray*). Já a função img_to_array irá converter as imagens no formato PIL para *arrays* do NumPy, e finalmente os *arrays* são divididos por 255, para normalização dos dados. A figura 47 mostra o

funcionamento completo desse pré-processamento baseado nas funções apresentadas previamente, (Silva, 2022) destaca que as imagens possuem como altura e largura 244 x 244 e estão na escala de cores de cinza, então a dimensão do canal assume o valor “1” e o formato de entrada da rede neural é de 244 x 244 x 1.

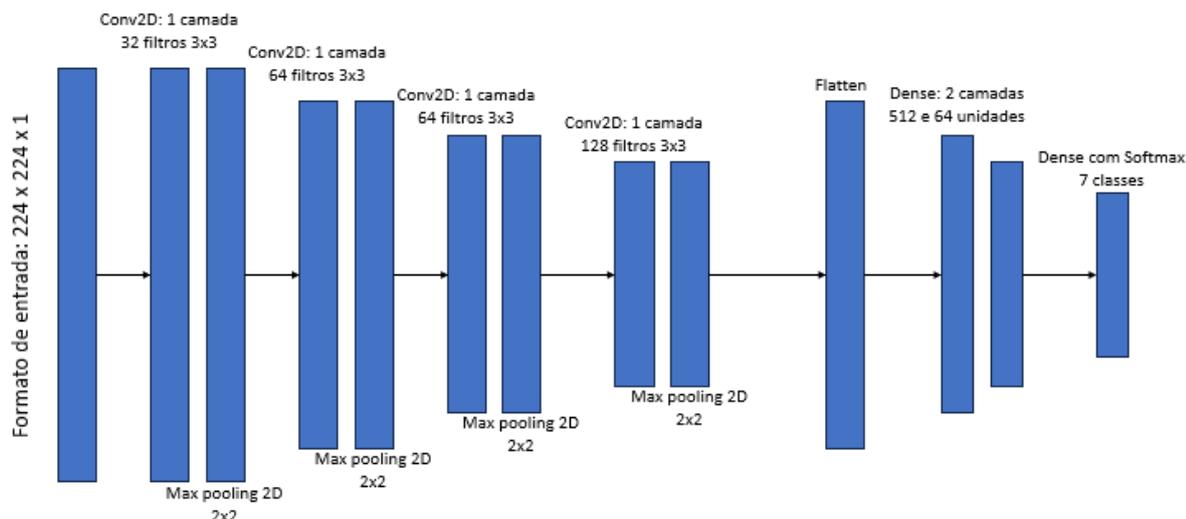
Figura 47 Ilustração de processamento com funções do TensorFlow



Fonte: Adaptado de Silva, 2022

Além da alteração no pré-processamento das imagens, ao invés de 5 *epochs* agora são 300, a estrutura da rede recebe suas camadas de acordo com a figura 48. Conforme (Silva, 2022) a última camada do tipo *dense* possui sete unidades uma para tecidos sem defeitos e as demais para tecidos defeituosos, um para cada trama. O treinamento dessa *convnet* foi de 2 horas e 10 minutos.

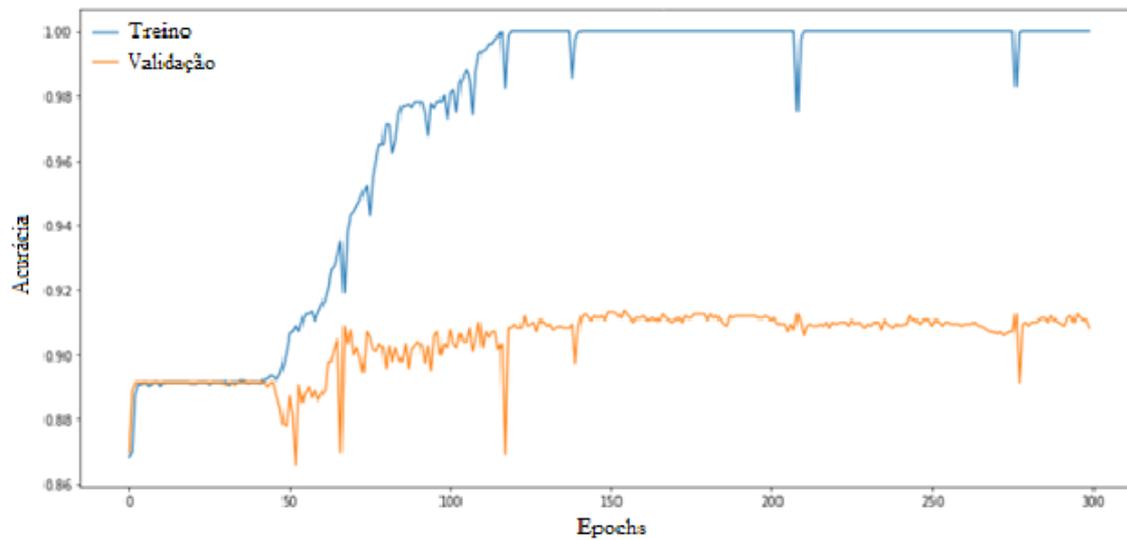
Figura 48 Rede neural convolucional com mudanças no pré-processamento



Fonte: Adaptado de Silva, 2022

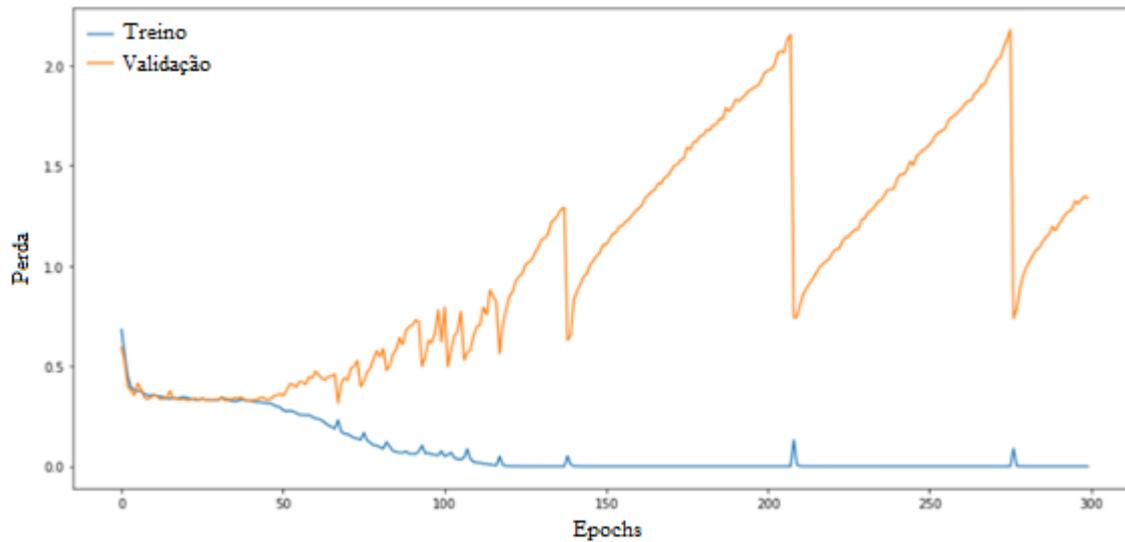
A seguir na figura 49 é possível observar os resultados do treino atingindo 100% e a acurácia em torno de 91% em ambas as curvas, é notável as oscilações ao longo das *epochs*, quais são estabilizadas conforme avança o treino. A figura 50, apresenta que para dados de treino a curva minimizou e chegou a ordem de grandeza de 10^{-7} . Por outro lado, a curva apresentou grandes oscilações, com tendencia de crescimento, chegando a aproximadamente 1,4, no final do treinamento. De acordo com (Silva, 2022) as grandes variações observadas ao longo das *epochs* ocorreram de forma sincronizada, ou seja, sempre que a perda do treino aumentava sutilmente, a perda da validação caía de forma drástica, logo que a perda do treino diminuía novamente e a validação aumentava ao longo das *epochs*, até a repetição desse comportamento.

Figura 49 Acurácia da *convnet* com melhorias para classificar defeitos em tecidos



Fonte: Silva, 2022

Figura 50 Perda da *convnet* para classificar imagens de tecidos

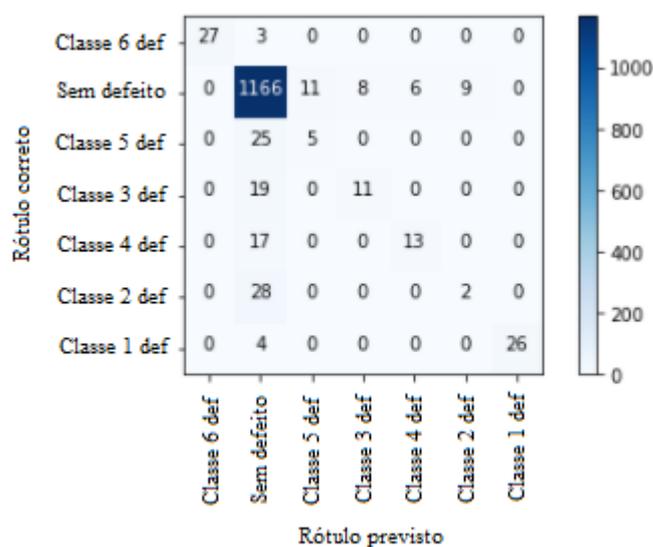


Fonte: Silva, 2022

A representação da figura 51, segundo (Silva, 2022) detalha os resultados de classificação com as imagens do *dataset* de teste, qual foi analisado 1200 imagens sem defeitos, o modelo acertou 1166 o que representa um aproveitamento de 97,17%. Para as classes 1 e 6, a *convnet* apresentou bons resultados, acertando 26 e 27 classificações, respectivamente, de um total de 30 imagens para cada. As classes 3

e 4, o modelo classificou corretamente 11 para a classe 3 e 13 para classe 4. As classes 2 e 5 tiveram apenas 2 e 5 imagens acertadas nessa ordem, para facilitar a visualização, na figura 52 é possível observar os resultados de classificação somente para imagens de tecidos defeituosos, com o percentual de aproveitamento para cada classe. As classes 2 e 5 apresentam os piores resultados e estão marcadas em vermelho por outro lado as classes 1 e 6, com boas classificações estão em verde. As classes 3 e 4, estão sem coloração já que podem ser consideradas como resultados medianos.

Figura 51 Matriz de confusão de rede com melhorias aplicadas para classificar tecidos



Fonte: Silva, 2022

Figura 52 Taxas de aproveitamento para classificação de tecidos com pré-processamento melhorado

	Aproveitamento (%)
Classe 1	86,70%
Classe 2	6,70%
Classe 3	36,70%
Classe 4	43,30%
Classe 5	16,70%
Classe 6	90,00%

Fonte: Adaptado de Silva, 2022

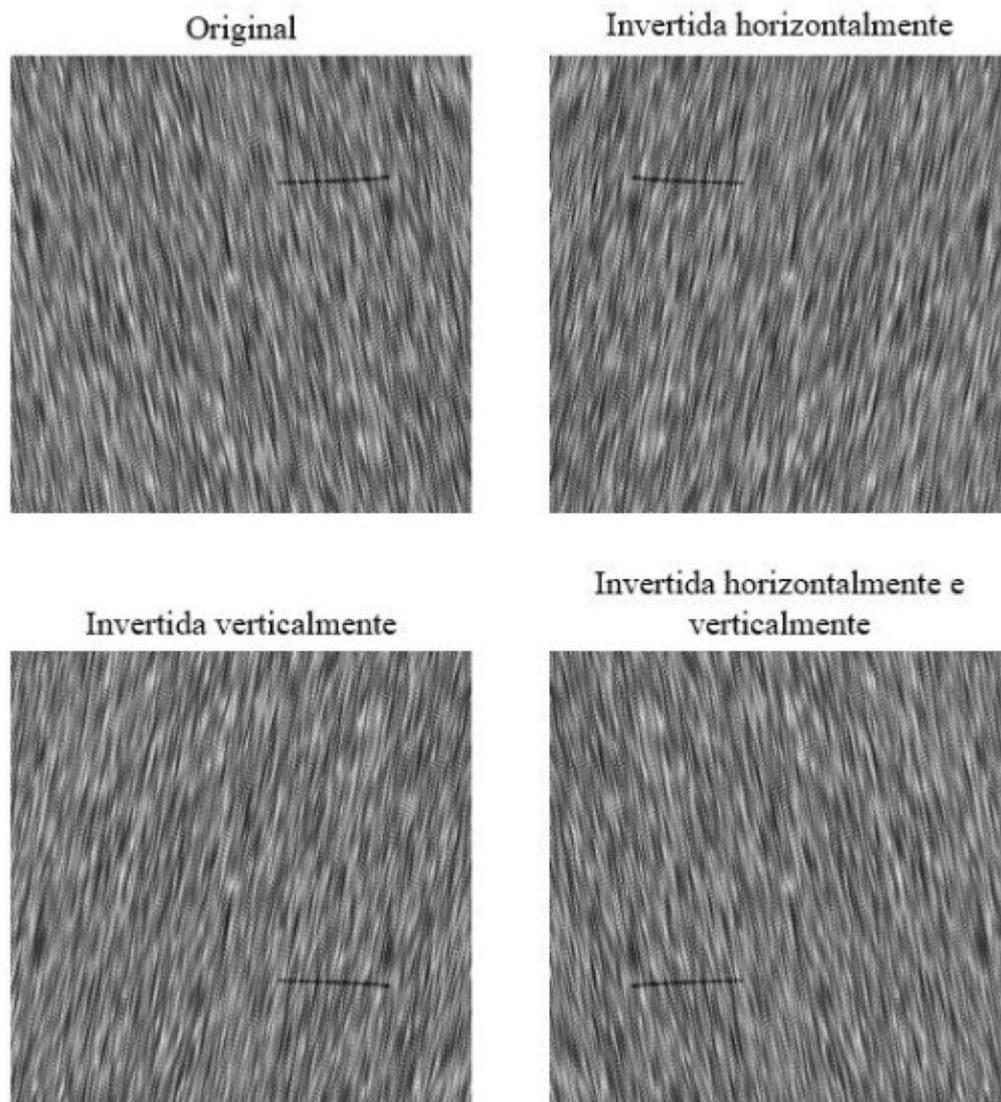
Como foi possível constatar com os dados fornecidos, que o modelo não obteve bons resultados para classificar defeitos em todas as classes, será necessário

aplicar *data augmentation* com a finalidade de atingir um resultado melhor nessas classes.

O *data augmentation* é uma estratégia que envolve a expansão do conjunto de dados por meio da criação de novas imagens. Essas imagens adicionais são criadas através da aplicação de diversas modificações nas imagens já presentes no conjunto de dados, evitando, assim a duplicação de informações. Conforme (Silva, 2022) o *data augmentation* é uma ferramenta poderosa para mitigar o *overfitting* em problemas de computação visual. Foi utilizado 6900 imagens em toda a base de tecidos, dos quais apenas 900 são imagens de tecidos defeituosos. O *data augmentation* será utilizado para diminuir esse desbalanceamento dos dados, sendo aplicado apenas para transformar e gerar mais imagens de tecidos com defeitos.

Como a classe 2 de tecidos obteve o pior resultado o *data augmentation* será aplicado somente em imagens com defeito dessa classe, em um total de 1150 imagens, apenas 150 serão com defeito. Conforme (Silva, 2022), cada imagem de tecido defeituoso, irá gerar outras três imagens novas, utilizando inversão vertical, horizontal e ambas a figura 53 representa essa transformação na prática, dessa maneira as imagens com defeitos serão quadruplicadas a quantidade de imagens de tecidos defeituosos passa a ser de 600 figuras de tecidos defeituosos após o *data augmentation*.

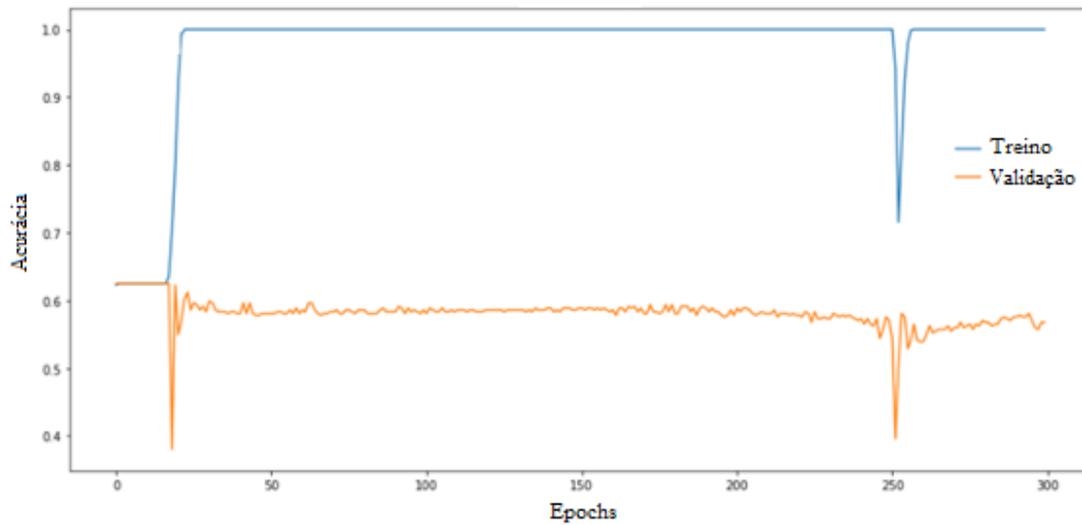
Figura 53 Exemplo de data augmentation



Fonte: Silva, 2022

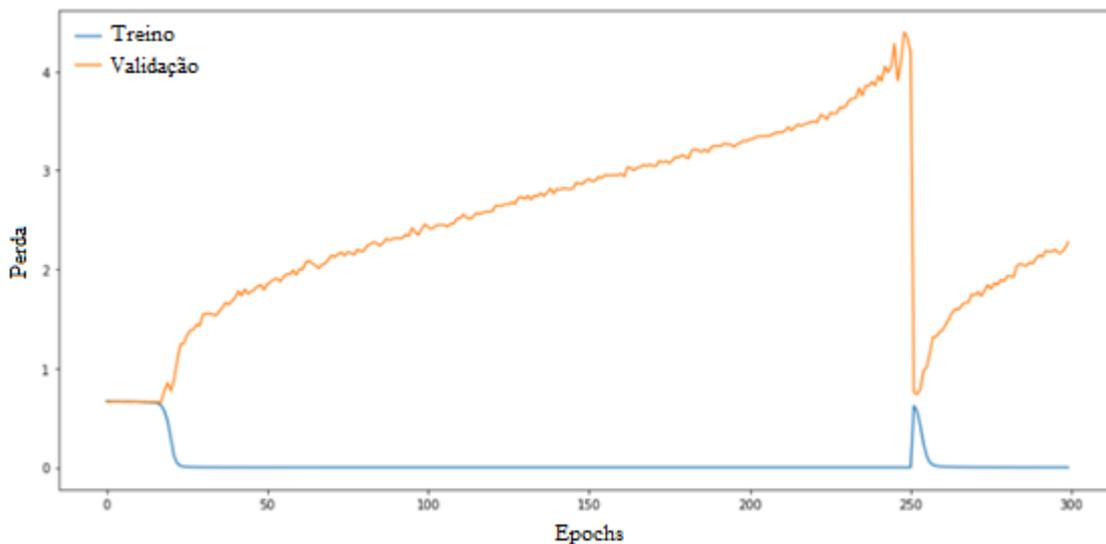
De acordo com (Silva, 2022) o tempo para o treinamento foi de 10 minutos e 22 segundos, a figura 54 revela que existe uma grande discrepância entre os resultados com dados de treino e validação. Com imagens de treino a acurácia chegou a 100% com imagens de treino, já na validação o modelo fica em torno dos 57%, apresentando oscilações. É possível perceber a ocorrência do *overfitting*. Na figura 55 também é possível perceber que não houve uma generalização adequada, para dados de treino, a perda minimiza rapidamente, chegando a valores da ordem de grandeza 10^{-4} . (Silva, 2022) destaca que antes da *epoch* 50, a perda para imagens destinadas à validação aumenta, chegando a valores maiores que 4.

Figura 54 Acurácia de *convnet* com *data augmentation* para classificar tecidos da classe 2



Fonte: Silva, 2022

Figura 55 Perda de *convnet* com *data augmentation* para classificar tecidos da classe 2

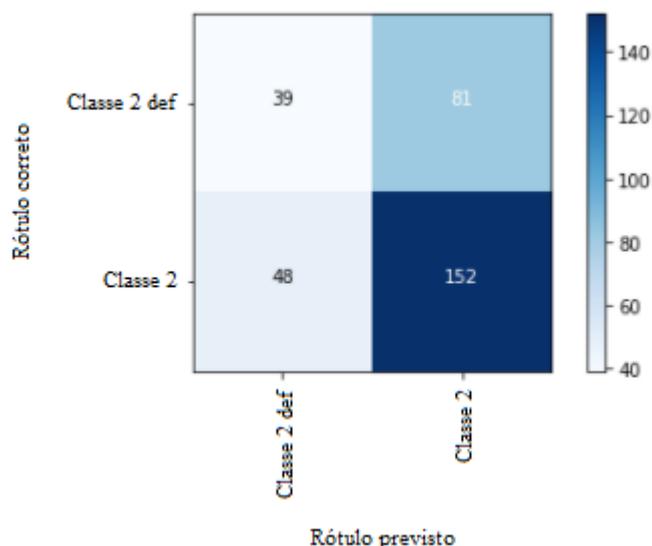


Fonte: Silva, 2022

A matriz de confusão presente na figura 56, mostra que das 200 imagens sem defeito o modelo classificou corretamente 152, uma taxa de 76%. Por outro lado, observando as imagens sem defeito, de 120 a rede acertou 39, ou seja 32,5% de aproveitamento. De modo geral o modelo foi de 59,7%, classificando corretamente 191 dos 320 tecidos da classe 2, ou seja, nem mesmo com o *data augmentation* o

modelo não apresentou bons resultados. No entanto, a taxa para classificação de defeitos ficou quase cinco vezes maior, em comparação com o modelo sem *data augmentation* como mostra a figura 57.

Figura 56 Matriz de confusão com *data augmentation* para classificar tecidos da classe 2



Fonte: Silva, 2022

Figura 57 Comparação de taxa de aproveitamento com e sem *data augmentation* na classe 2

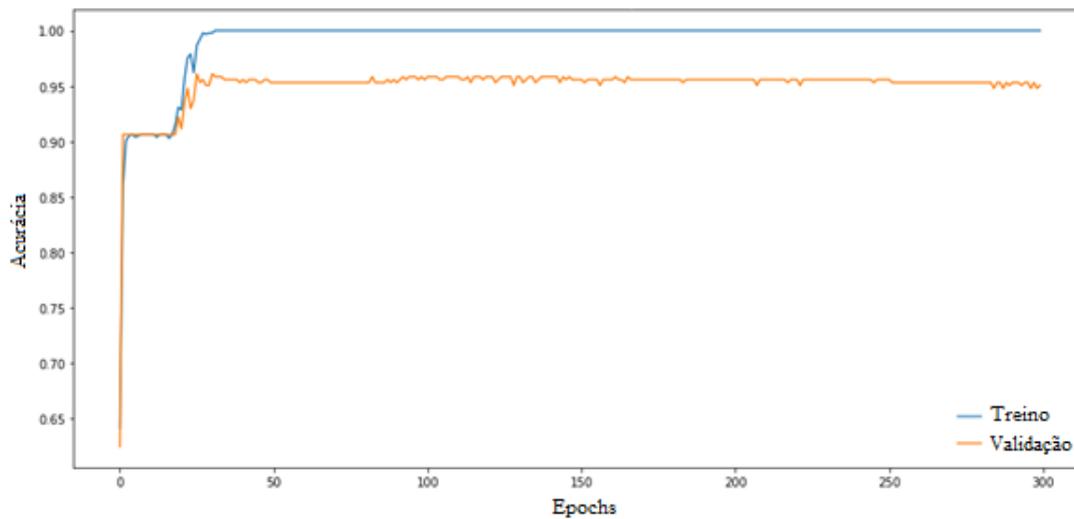
	Sem data augmentation	Com data augmentation
Classe 2	6,70%	32,50%

Fonte: Adaptado de Silva, 2022

Para melhoria na detecção de defeitos na classe 5, (Silva, 2022) também fez usos do *data augmentation*, foram utilizados as mesmas bibliotecas, módulos e métodos nesse modelo. O tempo de treinamento nessa para os defeitos na classe 5 foi de 29 minutos e 22 segundos.

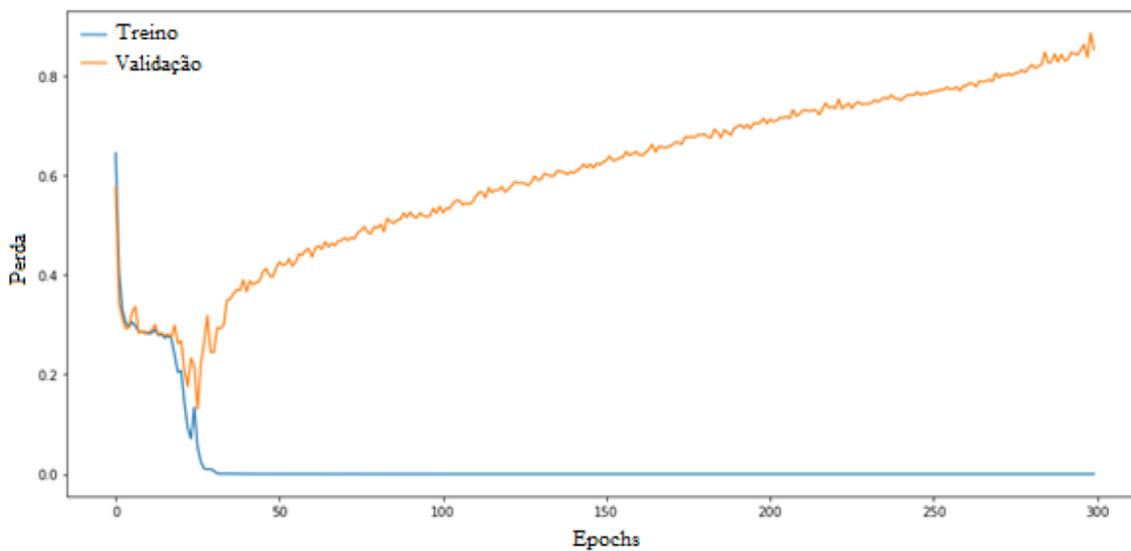
O gráfico de acurácia, conforme apresenta a figura 58, mostra que os resultados de treino chegam a 100%, ao analisar a acurácia é perceptível que o modelo foi capaz de generalizar de adequadamente, chegando a 95%, já na figura 59 qual apresenta o gráfico de perda é possível observar que, para os dados de treino, os resultados são minimizados atingindo a ordem de grandeza 10^{-10} . Para validação vemos que, por volta da *epoch* 30 a perda começa aumentar até a última *epoch*.

Figura 58 Figura 54 Acurácia de *convnet* com *data augmentation* para classificar tecidos da classe 5



Fonte: Silva, 2022

Figura 59 Perda de *convnet* com *data augmentation* para classificar tecidos da classe 5

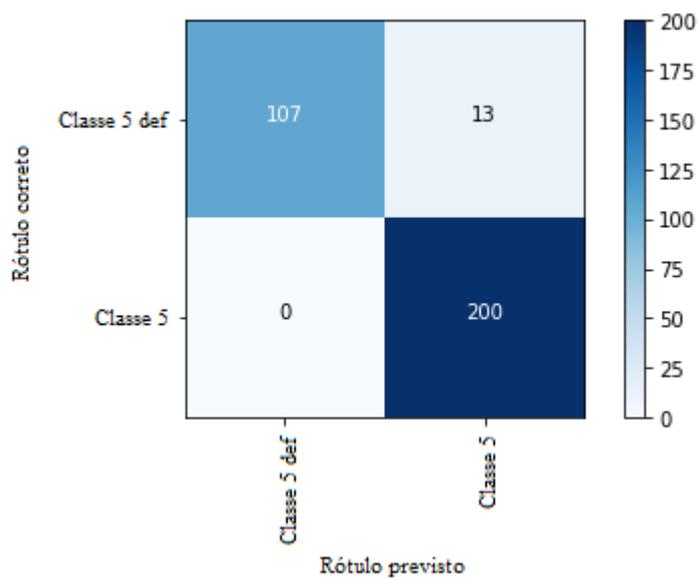


Fonte: Silva, 2022

A matriz de confusão na figura 60 vemos que o modelo classificou corretamente todas as 200 imagens sem defeito. Conforme (Silva, 2022) dos 120 tecidos defeituoso, a rede neural acertou 107, obtendo um aproveitamento de 89,71%, com isso a taxa de acerto da *convnet* foi de 95,94%. Assim é possível constatar que

a aplicação do *data augmentation* para imagens defeituosos da classe 5 gerou bons resultados, como mostra a figura 61.

Figura 60 Matriz de confusão com data augmentation para classificar tecidos da classe 5



Fonte: Silva, 2022

Figura 61 Comparação de taxa de aproveitamento com e sem *data augmentation* na classe 5

	Sem data augmentation	Com data augmentation
Classe 5	16,70%	89,20%

Fonte: Adaptado de Silva, 2022

4 IMPLEMENTAÇÃO DE INTELIGÊNCIA ARTIFICIAL NO PROCESSO DE REVISÃO

Nesse capítulo, exploraremos possíveis implementações futuras de inteligência artificial no processo de revisão de tecidos planos. Considerando que a IA ainda não foi integrada ao processo, discutiremos como essa integração poderia ocorrer no futuro e como poderia trazer melhorias significativas. Além disso, examinaremos a importância da análise de dados no contexto dessas futuras implementação.

4.1 COLETA DE DADOS PARA TREINAMENTO

Uma etapa inicial seria a coleta de um extenso conjunto de dados de imagens de tecidos planos. Isso incluiria imagens de tecidos com e sem defeitos, bem como informações detalhadas sobre os tipos de defeitos que podem ser encontrados. Esses dados seriam essenciais para treinar um modelo de rede neural eficaz.

4.2 TREINAMENTO DE UM MODELO DE IA

Após a aquisição dos dados, um modelo de IA, como uma Rede Neural Convolutiva (CNN), seria treinado usando esses dados. O treinamento envolveria a exposição do modelo a uma ampla variedade de tecidos planos para ensiná-lo a reconhecer padrões e defeitos.

4.3 IMPLEMENTAÇÃO PROGRESSIVA

Uma abordagem progressiva seria adotada para a implementação da *convnet* no processo de revisão isso envolveria testar o modelo em situações controladas e comparar seus resultados com a revisão humana. À medida que o modelo demonstrasse consistência e precisão, ele seria gradualmente integrado ao processo de revisão.

4.4 MELHORIAS CONTÍNUAS

Conforme a implementação avançasse, seria essencial buscar melhorias contínuas no modelo de IA. Isso poderia envolver aprimorar o treinamento, a incorporação de feedback de revisores humanos e a otimização do processo de integração.

4.5 ANÁLISE DE DADOS

A análise de dados desempenharia um papel crucial permitindo a avaliação do desempenho do modelo em comparação a revisores humanos, identificando áreas para aprimoramento e garantindo a qualidade do processo de revisão.

A análise de dados ajudaria a medir a eficácia do modelo de IA e identificar tendências nos tipos de defeitos encontrados. Além disso, a análise de dados seria vital para tomar decisões estratégicas sobre o aprimoramento contínuo do processo.

A implementação futura da IA no processo de revisão de tecidos planos representa uma oportunidade emocionante para melhorar a qualidade e eficiência na indústria têxtil. À medida que essa integração se desenvolve, é importante considerar cuidadosamente as etapas necessárias para garantir que a IA seja uma ferramenta valiosa na revisão de tecidos planos, com a análise de dados desempenhando um papel fundamental nesse processo em constante evolução.

5 CONCLUSÃO

Neste trabalho, exploramos extensivamente o papel transformador da Inteligência Artificial (IA) na classificação de tecidos planos, destacando sua capacidade de aprimorar a qualidade dos processos de fabricação e análise. Os avanços na IA, particularmente na aplicação de Redes Neurais Convolucionais (CNNs), podem proporcionar melhorias significativas na eficiência, precisão e automação da classificação de tecidos, com consequências profundas em termos de qualidade.

A qualidade, como um dos pilares de sucesso em qualquer setor, tem sido um foco essencial deste trabalho. A *convnet* demonstrou ser uma aliada poderosa na busca por padrões de qualidade rigorosos, ao mesmo tempo em que reduz a margem de erro humana. A automação da classificação de tecidos planos pode resultar em produtos finais mais consistentes e com menor probabilidade de defeitos. Isso não apenas melhora a satisfação do cliente, mas também economiza recursos e tempo, tornando a produção mais eficiente.

Além disso, não podemos subestimar o papel das técnicas de análise de dados na conclusão bem-sucedida da aplicação da IA. A rede neural não é apenas capaz de classificar imagens com precisão, mas também gera um volume significativo de dados valiosos. A análise desses dados é fundamental para entender melhor os processos de fabricação, identificar tendências, antecipar problemas e otimizar estratégias de produção. As técnicas de análise de dados, como a mineração de dados e a aprendizagem de máquina, complementam o poder da IA permitindo *insights* mais profundos.

É evidente que a inteligência artificial está se tornando uma ferramenta indispensável para melhorar a qualidade e eficiência em vários setores. Ao analisar e compreender os dados coletados pela IA, somos capazes de tomar decisões informadas e proativas, tornando as operações mais ágeis e eficazes. A IA não apenas simplifica processos, mas também agrega valor à qualidade do produto, permitindo a detecção precoce de defeitos e a otimização contínua.

No entanto, o progresso não é estático. À medida que novas técnicas e tecnologias continuam a se desenvolver, a IA na classificação de tecidos planos também evoluirá. É imperativo acompanhar esses avanços e estar disposto a adaptar as estratégias à medida que o campo da IA evolui.

Esta pesquisa destaca que a IA não é apenas uma ferramenta eficaz para a classificação de tecidos planos, mas também uma força motriz na melhoria da qualidade e no avanço da eficiência em operações de fabricação. Ela não apenas se encaixa harmoniosamente no cenário industrial, mas também ilumina o caminho para um futuro de maior inovação e qualidade aprimorada.

Em última análise, o casamento da IA com técnicas de análise de dados nos oferece uma visão abrangente e valiosa dos processos de classificação de tecidos planos. A qualidade não é apenas um resultado, mas um compromisso contínuo com a excelência, impulsionado pela IA e fundamentado em dados.

REFERÊNCIAS

- ABIT. (01 de Setembro de 2023). *Abit: a casa da indústria têxtil e de confecção*. Fonte: Abit: <https://www.abit.org.br/cont/perfil-do-setor>
- Albuquerque, F. F. (1987). *Controle de qualidade na indústria de fiação e tecelagem*. Rio de Janeiro: Senai/CETIQT.
- Alura. (21 de Setembro de 2023). *Alura*. Fonte: Alura: <https://www.alura.com.br/artigos/o-que-e-um-histograma>
- Associação Brasileira de Normas Técnicas. (2012). *Guia de Implementação: Normas para confecção de jeans*. Rio de Janeiro: ABNT;SEBRAE.
- Avani. (14 de 09 de 2023). *Technology Comnpany - Avani Viet Nam*. Fonte: Avani : <https://avani.vn/en/thong-andon-trong-san-xuat-tinh-gon-cua-toyota/>
- Community, U. (12 de 10 de 2023). *Medium is a home for human stories and ideas*. Fonte: Medium: <https://medium.com/@urapython.community/perceptron-com-python-uma-introdu%C3%A7%C3%A3o-f19aaf9e9b64>
- Crus, P. G. (2019). *Uma proposta de aplicação de inteligência artificial no processo de revisão de tecidos na indústria têxtil*. Apucarana: Universidade Tecnológica Federal do Paraná.
- Dennis, P. (2008). *Produção Lean Simplificada: Um guia para entender o sistema de produção mais poderoso do mundo (2ª ed.)*. Porto Alegre: Bookman.
- Guariete, P. A., & de Larmelina, É. (16 de Junho de 2016). *Engenharia da qualidade: Aplicação das ferramentas clássicas em um processo produtivo de uma indústria têxtil*. Medianeira, Paraná, Brasil: Universidade Tecnológica Federal do Paraná.
- Montgomey, D. C. (2017). *Introdução ao Controle Estatístico da Qualidade*. Rio de Janeiro: LTC.
- Neves, M. d. (2012). *Qualidade de tecidos Denim, Desafios do revisor*. Americana: Faculdade de Tecnologia de Americana.
- Nicolau, N. K. (s.d.). *Representação da torção Z e S*. Americana.
- Omatex. (25 de Setembro de 2023). *Omatex indústria e comercio de máquinas têxteis*. Fonte: Omatex indústria e comercio de máquinas têxteis: <https://www.omatex.com.br/index.php/produto/revisadeira-para-malha-e-tecido-plano-com-painel-de-revisao-de-500-mm-e-controle-de-tensao-mod-omr-ct1-r/>

Paladini, E. P., Bouer, G., Carvalho, M. M., Miguel, P. A., Samohyl, R. W., & Rotondaro, R. G. (2012). *Gestão da qualidade: Teoria e Casos*. Rio de Janeiro: Elsevier Editora LTDA.

Pezzolo, D. B. (2017). *Tecidos história, tramas, tipos e usos*. São Paulo: Senac São Paulo.

Raush, P. h. (2022). *Proposta de estruturação de um sistema de qualidade para redução de defeitos: Um estudo de caso em uma indústria têxtil de santa catarina*. Blumenau: Universidade Federal de Santa Catarina.

Silva, L. A. (2022). *Redes neurais convolucionais com python e google colab: Estudo de caso de detecção de defeitos em tecidos*. Niterói: Universidade Federal Fluminense.

Vieira, O. F. (1988). *Controle de qualidade na industria de fiação e tecelagem* (Vol. II). Rio de Janeiro: SENAI/CETIQ.

Zeev. (21 de Setembro de 2023). Zeev. Fonte: Zeev: <https://blog.zeev.it/diagrama-de-pareto/>