

CENTRO UNIVERSITÁRIO IBMR

CAROLINE BASTOS GAVINHO

ERIC BAYÃO VAZ

VICTÓRIA DE FREITAS LESSA

**USO DE RNA PARA CONTROLE DE QUALIDADE
NA DETECÇÃO DE DEFEITOS, ATRAVÉS DE IMAGENS
DIGITAIS**

RIO DE JANEIRO

2023

**CAROLINE BASTOS GAVINHO
ERIC BAYÃO VAZ
VICTÓRIA DE FREITAS LESSA**

**USO DE RNA PARA CONTROLE DE QUALIDADE
NA DETECÇÃO DE DEFEITOS, ATRAVÉS DE IMAGENS
DIGITAIS**

Trabalho de Conclusão de Curso,
apresentado a Escola de Engenharias do
Centro Universitário IBMR como requisito
parcial para a obtenção do título de
Engenheiro(a) de Produção.

Orientador: Esp. Sabrina Molina

**RIO DE JANEIRO
2023**

12,5 cm

**FICHA CATALOGRÁFICA FEITA PELA
BIBLIOTECA DA UNIVERSIDADE**

COLOCADA NO VERSO DA FOLHA DE ROSTO.

7,5 cm

CAROLINE BASTOS GAVINHO
ERIC BAYÃO VAZ
VICTÓRIA DE FREITAS LESSA

USO DE RNA PARA CONTROLE DE QUALIDADE
NA DETECÇÃO DE DEFEITOS, ATRAVÉS DE IMAGENS
DIGITAIS

Trabalho de Conclusão de Curso,
apresentado a Escola de Engenharias do
Centro Universitário IBMR como requisito
parcial para a obtenção do título de
Engenheiro(a) de Produção.

Aprovado em 07 de dezembro de 2023.

Prof.: Sabrina da Silva Molina – Orientador
Centro Universitário IBMR

Prof.: André Luiz Ribeiro Valladão - MSc.
Centro Universitário IBMR

Prof.: Paulo Ubiratan - MSc.
Centro Universitário IBMR

DEDICATÓRIA

Dedicamos este trabalho aos nossos familiares que tanto admiramos e nos apoiaram diretamente ao longo de todo este percurso.

AGRADECIMENTOS

A Deus por ter nos dado saúde e sabedoria ao longo de nossa trajetória.

Aos nossos pais pelo amor incondicional, pela paciência durante todo nosso processo de formação e principalmente por acreditarem no nosso potencial.

A nossa orientadora Sabrina Molina e coorientador Paulo Ubiratan pelos ensinamentos, conselhos e correções, que nos permitiu dar o nosso melhor na realização do trabalho.

“Assim como os pássaros estimularam a criação dos aviões, a natureza foi fonte de inspiração para inúmeras invenções humanas. Nesse sentido, parece lógico observar a arquitetura do cérebro humano em busca de inspiração sobre como construir uma máquina inteligente”.

Rogério Ferreira

(2021)

RESUMO

Este presente trabalho tem como objetivo aprofundar o entendimento sobre as redes neurais artificiais como uma técnica de aprendizado de máquinas para a detecção de defeitos em uma linha de produção por meio de análise de imagens digitais. A análise visa destacar a precisão e confiabilidade da aplicação de redes neurais artificiais como uma ferramenta eficaz para garantir a qualidade no processo de produção, contendo a ocorrência de falhas. Ao concentrar-se na identificação de imperfeições por meio da análise de imagens digitais, a pesquisa visa fornecer uma percepção sobre como as redes neurais artificiais podem ser empregadas como uma ferramenta para aprimoramento na eficácia e a precisão na detecção de defeitos em um ambiente industrial. Desta forma, busca-se enfatizar não apenas a capacidade das redes neurais artificiais na detecção de padrões complexos, mas também sua aplicabilidade prática na otimização do controle de qualidade. Através deste estudo, buscamos fortalecer a compreensão do papel fundamental das redes neurais artificiais na indústria, enfatizando seu potencial para agregar valor através da fabricação conforme as especificações, elevar os padrões de qualidade baseada na fabricação, prevenir falhas, contribuir de maneira significativa para a eficiência operacional em ambientes de produção, reduzindo assim gastos com retrabalhos e desperdícios de matéria prima.

Palavras-chave: Redes Neurais Artificiais, Controle de Qualidade, Detecção de Defeitos, Aprendizado de máquinas.

ABSTRACT

This work has the objective to deepen the understanding of artificial neural networks as a machine learning technique for detecting defects in a production line through the analysis of digital images. The analysis aims to high the precision and reliability for the application of artificial neural networks as an effective tool to secure the quality in the production process, preventing the occurrence of fails. When we focus on identifying imperfections through digital image analysis, the search aims to promote insights into how artificial neural networks can be employed as a tool for improving the effectiveness and accuracy of defect detection in an industrial environment. In this case, we search to emphasize not only the capacity of artificial neural networks in detecting complex patterns, but also their practical applicability in optimizing quality control. Through this study, we are looking to get a strong understanding of the fundamental role of artificial neural networks in industry, emphasizing their potential to aggregate value through manufacturing to specifications, raise manufacturing-based quality standards, prevent fails, and contributing significant wood to efficiency. operational in production environments, thus reducing expenses with rework and waste of raw materials.

Keywords: Artificial Neural Networks, Quality Control, Defect Detection, Machine Learning.

LISTA DE FIGURAS

Figura 1	- Estrutura da pesquisa exploratória.....	18
Figura 2	- Modelo RNA camada única.....	20
Figura 3	- Modelo RNA múltiplas camada.....	21
Figura 4	- Imagem de madeira serrada de Pinus Taeda	26
Figura 5	- Imagem de madeira serrada de Pinus Elliottii	26
Figura 6	- Fluxo do processo de classificação de tábuas	27
Figura 7	- Imagem do processo de remoção do fundo.....	27
Figura 8	- Imagem das tábuas de 128x128 pixels.....	28
Figura 9	- Imagem das tábuas de 64x64 pixels.....	28
Figura 10	- Imagem das tábuas de 32x32 pixels.....	28
Figura 11	- Taxa de ocupação de defeito das tábuas de 64x64 pixels.....	29
Figura 12	- Fluxo para inspeção de caixas.....	30
Figura 13	- Pré processamento de caixas sem defeito	31
Figura 14	- Pré processamento de caixas com defeito	32
Figura 15	- Ausência de defeitos em caixas.....	34
Figura 16	- Presença de defeitos na pintura das caixas.....	35

LISTA DE TABELAS

Tabela 1	- Dados de aprendizado RNA MLP	29
Tabela 2	- Grupos de treinamento usando RNA MLP	33
Tabela 3	- Classificação correta e incorreta de RNA	35

GLOSSÁRIO DE SIGLAS E SÍMBOLOS

IA	-	Inteligência Artificial
MCNC	-	Matriz de Co-ocorrência de Níveis de Cinza
MLP	-	Rede Neural Perceptron Multicamadas
RNA	-	Rede Neural Artificial

SUMÁRIO

1 – INTRODUÇÃO	15
1.1 Problema	17
1.2 Objetivos	17
1.2.1 Objetivo Geral	17
1.2.2 Objetivos Específicos	17
1.3 Justificativa	17
1.4 Metodologia	18
1.5 Estrutura do trabalho	19
2 – REVISÃO BIBLIOGRAFICA	19
2.1 Definição de RNAs	19
2.1.1 Definição de RNAs múltiplas camadas.....	21
2.2 Extração de características em imagens.....	22
2.3 Controle de qualidade	22
2.3.1 Baseado na fabricação.....	23
2.3.2 Transcendental.....	23
2.3.3 Baseado no produto	24
2.3.4 Baseado no usuário	24
2.3.5 Baseado no valor	24
3 – ESTUDO DE CASOS	25
3.1 Metodologia usada em uma serralheria	25
3.2 Metodologia usada em uma linha de produção de caixas.....	30
4 – RESULTADOS E ANÁLISE.....	32
4.1 Dados do uso de RNA em uma serralheria	32
4.2 Dados do uso de RNA em uma linha de produção de caixas	34
4.3 Análise.....	36
5 – CONCLUSÃO.....	37
REFERÊNCIAS BIBLIOGRÁFICAS	38

1. INTRODUÇÃO

Em uma indústria, garantir a excelência dos produtos e dos procedimentos é vital para o seu êxito. Isso ocorre porque a qualidade dos produtos está, em sua maioria, ligada capacidade de produção padronizada, sem defeitos, e qualquer falha pode acarretar altos custos (BRITTO, 2015). Uma forma de verificar se os produtos estão de acordo com as normas e expectativa dos *stakeholders*¹, é realizar inspeções visuais nos lotes produzidos. Essas inspeções têm a finalidade de identificar quaisquer irregularidades nos produtos fabricados.

Em geral, as inspeções visuais são realizadas manualmente, o que acarreta custos elevados, possíveis falhas e dificuldades em manter um padrão consistente. Com o avanço das tecnologias, sistemas de visão têm possibilitado a automatização dessas inspeções. Eles são capazes de conceder às máquinas a habilidade de enxergar, permitindo a identificação automática de características e defeitos nos produtos. (FELICIANO; SOUZA; LETA, 2010)

Sistemas desse tipo garantem precisão e repetibilidade nas medições sem necessidade de um operador, eliminando fatores como subjetividade, fadiga, lentidão e os custos associados à inspeção realizada por seres humanos (FELICIANO; SOUZA; LETA, 2010). Portanto, são mais eficazes, seguros e rápidos, já que ultrapassam as capacidades visuais humanas.

Esses sistemas de visão podem ser aplicados em diversas indústrias para classificar objetos e detectar imperfeições. Alguns exemplos da técnica já desenvolvidos, Bhatt e Pant (2015) utilizaram um sistema de visão computacional para classificar maçãs com base nas características físicas, como tamanho, cor e imperfeições na casca. Andrade (2013) substituiu a inspeção humana, em um sistema inspeção para classificar as cores das embalagens de produtos químicos agrícolas, por uma inspeção automatizada. Pessota (2013) propôs um método para classificar diferentes variedades de feijão com base na cor de suas cascas.

Um sistema de visão pode ser dividido em etapas como, a aquisição de imagens, a segmentação, a aprimoramento da qualidade da imagem, a extração de

¹ Público estratégico e descreve todas as pessoas ou “grupo de interesse” que são impactados pela ação.

características e, por fim, o reconhecimento de padrões (BACKES; JUNIOR, 2016). A aquisição envolve a captura de imagens digitais dos produtos, enquanto a segmentação e o aprimoramento são empregados para realçar a parte significativa e melhorar a qualidade da imagem, removendo ruídos que poderiam prejudicar as etapas subsequentes. Já a extração de características tem o propósito de coletar dados relevantes sobre a imagem segmentada, essenciais para sua classificação. Por fim, a etapa final é realizada por algoritmos de classificação, que usam as características extraídas para categorizar os produtos em grupos, como defeituosos ou não defeituosos. (ALMEIDA, 2014)

Os algoritmos de classificação são desenvolvidos usando técnicas de Inteligência Artificial (IA). Por meio da IA, agentes inteligentes podem ser criados para realizar tarefas que normalmente exigiriam inteligência humana (RUSSELL; NORVIG, 2013). De acordo com Mohanan et al. (2016), os modelos de IA usados para o reconhecimento de padrões incluem correspondência por padrão, abordagem estatística, abordagem sintática/estrutural, Redes Neurais Artificiais (RNAs), modelos baseados em lógica fuzzy e abordagens híbridas. Entre todos esses modelos, as RNAs se destacam devido à sua capacidade de tolerância a falhas.

Portanto, dada a importância do assunto, o presente trabalho propõe uma melhoria no processo de identificação de defeitos em uma linha de produção, por meio da utilização de técnicas de aprendizagem de máquinas, com uso de Redes Neurais Artificiais (RNA), uma tecnologia que tem ganhado destaque para finalidade comercial e que tem como objetivo a coleta com qualidade de informações em menor tempo, otimizando o processo.

1.1 Problema

O controle de qualidade é uma peça fundamental na produção industrial, garantindo a conformidade dos produtos aos padrões estabelecidos. Apesar dos avanços nas técnicas de controle, persistem desafios significativos na detecção precoce de defeitos e na otimização dos processos, que têm o potencial de afetar a percepção da marca pelo consumidor público.

Este problema necessita de um aprimoramento no controle de qualidade, prevenindo a ocorrência de falhas durante a produção, evitando desperdícios de matéria prima e retrabalhos.

1.2 Objetivos

1.2.1 Objetivo geral

Este artigo propõe uma pesquisa acerca da viabilidade na utilização de redes neurais artificiais (RNAs) na indústria, para classificação de objetos com defeitos e sem defeitos.

1.2.2 Objetivo específico

- Estudo de caso na aplicação de RNAs para detecção de defeitos através de imagens;
- Proporcionar o uso de RNAs como uma ferramenta de controle de qualidade no meio da produção.
- Otimização dos processos para redução de falhas.

1.3 Justificativa

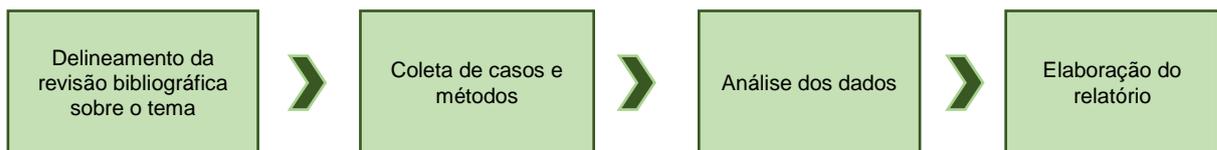
A pesquisa em cima da qualificação do programa de imagens na detecção de defeitos é contribuir para empresas desenvolverem futuramente essa técnica no seu chão de fábrica, podendo proporcionar um conhecimento e curiosidade em explorar essa técnica computacional. Suas efetivas respostas abordadas nesse trabalho através do estudo de casos, comprovam o quão benéfico a automatização desse serviço possa trazer ganhos significativos na produtividade e modernização dentro de seus processos.

1.4 Metodologia

Para alcançar esse objetivo, a pesquisa exploratória foi baseada em análise estudo de casos buscando através da junção de métodos de classificação trabalhados com uma RNA chegar a resultados prósperos ao controlar a qualidade do produto. Nesse caso, foi necessário “desencadear um processo de investigação que identifique a natureza do fenômeno e aponte as características essenciais das variáveis que se quer estudar.” (KÖCHE, 1997).

A seguir serão descritas na Figura 1, as etapas e as atividades utilizadas para realização dessa pesquisa.

Figura 1 – Estrutura da pesquisa exploratória



Fonte: Koche, 1997 (Adaptado pelos autores)

Durante a revisão bibliográfica sobre o tema exposto, foi realizado através do desenvolvimento de conceitos chaves para a abordagem das redes neurais artificiais como uma ferramenta para o controle de qualidade.

A coleta de dados se deu por meio de estudo de casos já desenvolvidos com o uso de RNA para detecção de defeitos através de imagens digitais, sendo explorado dois cenários diferentes, o primeiro em uma linha de produção de teste de detecção de defeitos na pintura de caixas e outra em uma serralheria para análise de nós² em tábuas de madeiras.

A análise de dados ocorreu dentro de um período de dez meses, entre fevereiro a outubro de 2023. Com intuito de apresentar a efetividade da técnica para o controle de qualidade na produção.

² Nós são geralmente têm uma aparência mais escura e mais densa do que a madeira ao seu redor. Eles representam pontos onde os ramos estavam ligados ao tronco.

O relatório apresenta o ponto de vista analítico embasado nos dados obtidos a partir dos testes apresentados nos estudos de casos alinhado a utilização da ferramenta para detecção de defeitos.

1.5 Estrutura do trabalho

Para organizar o artigo, ele foi dividido em capítulos. No primeiro capítulo contém a introdução acerca do conceito de Redes Neurais Artificiais, em um segundo capítulo aborda uma fundamentação teórica a respeito do tema, no terceiro capítulo abordamos a metodologia do uso das RNAs, no quarto capítulo levantamento de dados, com diversos estudiosos que testaram as RNAs, para detecção de defeito. E a partir desse levantamento analisamos a viabilidade do uso dessa ferramenta para uma linha de produção.

A pesquisa se deu pelo estudo de caso dos testes realizados por Almeida (2014) e Martins et al (2018), a fim de evidenciar por meio dessa pesquisa exploratória a eficácia do uso de redes neurais para detecção de falhas.

2. REVISÃO BIBLIOGRAFICA

Este primeiro momento consiste em apresentar ao leitor o principal objeto de estudo deste trabalho, transmitindo o conhecimento acerca do uso de RNAs de forma objetiva e coesa. Em seguida, a temática sobre um dos mecanismos que permite a extração de informações com base em imagens digitais, esse processo auxilia as redes neurais a realizarem a classificação de defeitos. Consequentemente, introduzindo o conceito de controle de qualidade para analisar os avanços em relação ao tema aqui proposto.

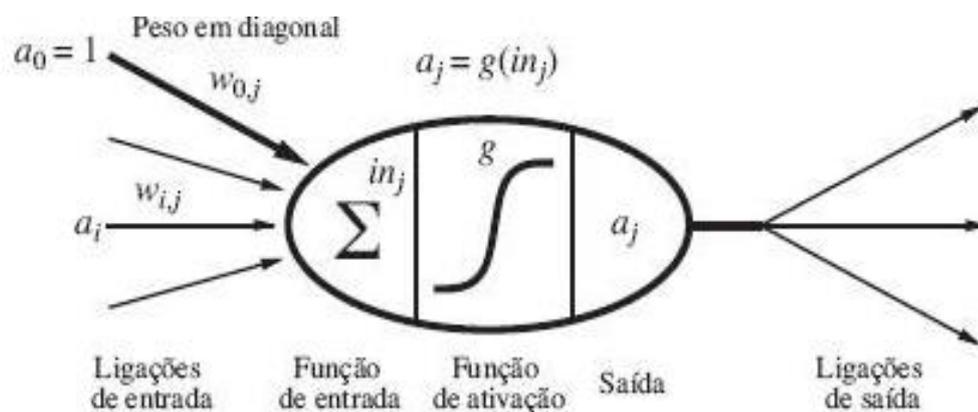
2.1 Redes Neurais Artificiais

A natureza foi fonte de inspiração para diversas descobertas científica, como os pássaros inspiraram os aviões, o cérebro humano inspirou as Redes Neurais Artificiais (RNA), a estrutura de RNA são modelos baseados no aprendizado de máquina que visam reproduzir o funcionamento das redes de neurônios presentes no cérebro humano. (FERREIRA ROGERIO, 2021)

As Redes Neurais Artificiais (RNAs) são paradigmas de IA inspirados no funcionamento do sistema nervoso biológico. Para resolver problemas, os neurônios se interconectam, colaborando na resposta a estímulos de entrada (MOHANAN et al., 2016). As RNAs possuem características fundamentais, incluindo aprendizagem (a capacidade de iniciar sem conhecimento e ser treinada com dados), generalização (produzir o melhor resultado para exemplos não utilizados no treinamento), paralelismo potencial massivo (neurônios ativados simultaneamente durante o processamento de dados), robustez (um desempenho dominado mesmo com alguns neurônios não funcionando melhor) e correspondência parcial (indicando que dados conhecidos não coincidem exatamente com novos eventos) (KASABOV, 1998).

Uma RNA consiste em unidades interconectadas, denominada neurônios. O modelo de camada de RNA único, conhecido como perceptron, foi desenvolvido por McCulloch e Pitts, é ativado quando a combinação linear das entradas ultrapassa um limiar pré-estabelecido, conforme ilustrado na Figura 2. (RUSSELL; NORVING, 2013)

Figura 2 - Modelo de Rede Neural Artificial de camada única



Fonte: RUSSELL; NORVING, 2013

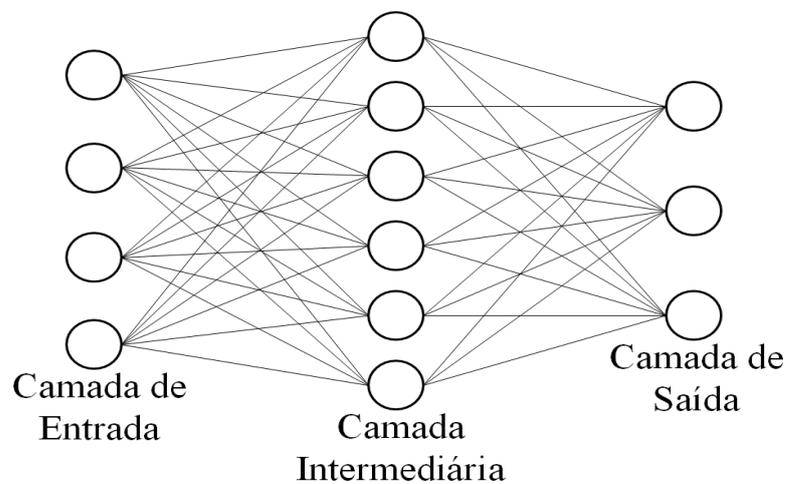
A construção de uma RNA pode envolver neurônios nas camadas de entrada e saída, para problemas lineares, ou pode incluir camadas intermediárias ou camada de ativação, para problemas não lineares. As conexões entre neurônios formam, reações chamadas de sinapses, se assemelhando ao cérebro humano, cada uma com seu próprio peso, que determina a influência de cada conexão. O neurônio

realiza o somatório do produto do valor de saída de cada neurônio vizinho pelo peso da sinapse que os liga. (MITCHELL, 1997).

2.1.1 Redes Neurais Multicamadas

Uma das arquiteturas mais populares de redes neurais artificiais é o Multi-Layer Perceptron – MLP, conforme representada na figura 3, que faz parte do grupo de RNA conhecido como retropropagação³. A retropropagação é um algoritmo amplamente utilizado para o treinamento de erros em RNAs. Esse algoritmo se baseia na regra de aprendizagem por correção de erro, cujo objetivo é minimizar o erro de treinamento ajustando os pesos das sinapses. As redes baseadas no MLP, treinadas por meio de retropropagação vem sendo amplamente aplicadas em diversas áreas do mundo real. (ALMEIDA, 2014)

Figura 3 – Representação de uma arquitetura de rede multi-camadas.



Fonte: Almeida 2014

³ É baseado na regra de aprendizagem por correção de erro, que tem como objetivo minimizar o erro de treinamento a partir dos ajustes dos pesos das sinapses.

2.2. Extração de Características em Imagens

O desempenho de qualquer algoritmo de classificação é fortemente influenciado pela quantidade e qualidade dos dados de entrada. (MITCHELL, 1997). Segundo a análise feita por Capizzi (2016), em seu estudo para detecção de defeitos com laranjas. Há vários tipos de técnicas de análise de imagens, para reconhecimento e classificação, entre as técnicas mais populares usadas na classificação de imagens 2D são baseadas em cores e textura. Portanto, a escolha da técnica de extração de características a ser empregada deve ser cuidadosamente selecionada de acordo com o tipo de característica desejada. Uma abordagem eficaz para a extração de informações relacionadas à textura de imagens é o uso da Matriz de Co-ocorrência de Nível de Cinza ⁴(MCNC), na qual a textura é analisada com base na distribuição espacial dos níveis de cinza em uma vizinhança.

A textura é categorizada com base na disposição espacial dos níveis de cinza em uma região vizinha, o que também auxilia na avaliação da superfície e da forma, portanto a matriz de co-ocorrência consegue representar de forma tabular as associações entre os valores de brilho dos pixels (níveis de cinza) (CAPIZZI, 2016). A utilização da matriz MCNC permite o cálculo de propriedades de textura, tais como contraste, energia, entropia e homogeneidade.

2.3 Controle de Qualidade

A qualidade da gestão é um dos princípios mais cruciais nos negócios, especialmente em um ambiente altamente competitivo. A criação de produtos e serviços de alta qualidade estabelece uma relação benéfica para as empresas, consumidores e sociedade. Isso resulta em vantagens para as organizações, pois a busca pela excelência na qualidade contribui para a redução de desperdícios. (BRITTO, 2015)

Garvin (2002) buscou organizar os conceitos de qualidade, identificando cinco abordagens principais para sua definição:

⁴ É algoritmo é baseado na regra de aprendizagem por correção de erro, que tem como objetivo minimizar o erro de treinamento a partir dos ajustes dos pesos das sinapses.

- 1- Baseado na fabricação;
- 2- Transcendental;
- 3- Baseado no produto;
- 4- Baseado no usuário;
- 5- Baseado no valor.

2.3.1 Baseada na fabricação

Segundo Garvin (2002, p. 53) As definições centradas na produção caracterizam a qualidade como conformidade com as especificações. Uma vez que uma concepção de projeto tenha sido estabelecida, qualquer desvio é interpretado como uma diminuição na qualidade. Portanto, a excelência é associada ao cumprimento rigoroso das especificações. Desta forma, um produto fabricado em estrita conformidade com as especificações é considerado de alta qualidade.

Praticamente todas as definições baseadas na produção identificaram a qualidade como conformidade com as especificações. Uma vez estabelecido um projeto ou uma especificação, qualquer desvio implica uma queda da qualidade. A excelência é equiparada ao atendimento das especificações e a fazer certo da primeira vez.

Segundo Garvin (2002, p. 53)

2.3.2 Transcendental

De acordo com essa abordagem, a qualidade é equivalente a uma excelência inata. Ela é considerada absoluta e universalmente identificável. Contudo, a qualidade não pode ser definida de maneira precisa, pois é uma propriedade simples e não sujeita a análise. A compreensão da qualidade ocorre apenas por meio da experiência e da observação.

2.3.3 Baseado no produto

Sob essa perspectiva, a qualidade é descrita como uma variável precisa e mensurável, sendo as discrepâncias na qualidade refletidas nas características de um produto. Essa abordagem resulta em uma dimensão vertical ou hierárquica de qualidade, permitindo a classificação dos produtos com base em suas características. Essa visão implica em dois pontos essenciais: em primeiro lugar, a qualidade é uma característica intrínseca dos produtos e pode ser avaliada de maneira objetiva; em segundo lugar, alcançar uma qualidade superior geralmente implica custos.

2.3.4 Baseado no usuário

Essa abordagem parte das ocupações, afirmando que a qualidade está nos olhos do observador/consumidor. A qualidade está vinculada a uma visão subjetiva. Pressupõe-se que os produtos que melhor atendem às preferências do consumidor sejam considerados de alta qualidade por ele. Essa abordagem deu origem ao conceito de pontos ideais (combinações precisas de atributos do produto que proporcionam maior satisfação a um consumidor específico). Além disso, inovação o conceito de adequação ao uso, amplamente presente na literatura sobre qualidade, definição de qualidade mais difundida.

2.3.5 Baseado no valor

Nesta perspectiva, a qualidade é definida em termos de custos e preços. Portanto, um produto extremamente caro em relação ao poder de compra do mercado, independentemente de sua qualidade intrínseca, não pode ser considerado um produto de qualidade, pois teria uma base de consumidores limitada.

A dificuldade dessa abordagem reside na combinação de dois conceitos relacionados, mas distintos: qualidade e valor. Isso resulta em um elemento híbrido, denominado "excelência adquirível", que carece de limites claramente definidos e é exigido de ser aplicado na prática. A coexistência dessas diversas abordagens explica os conflitos em relação à qualidade, por exemplo, no setor de alimentos, onde predominam abordagens centradas no produto e/ou no usuário, em contraste com a área de Produção, que favorece a abordagem baseada na fabricação.

De acordo com Garvin (2002), apesar do potencial para conflitos, é benéfico cultivar essas perspectivas divergentes, pois são essenciais para o lançamento bem-sucedido de produtos de alta qualidade. As características que definem a qualidade de um produto devem ser identificadas principalmente por meio de pesquisa de mercado (abordagem focada no usuário). Essas características devem então ser traduzidas em atributos identificáveis do produto (qualidade centrada no produto), e o processo produtivo deve ser organizado para garantir que os produtos estejam em conformidade com essas especificações (abordagem centrada na fabricação). Todos esses três aspectos são necessários e devem ser abordados de maneira consciente.

3. ESTUDO DE CASOS

Esse capítulo apresenta o desenvolvimento da RNA para detecção de defeito, apoiando-se em proposições teóricas já estabelecidas no processo de dois produtos diferentes que trazem metodologias diferentes, para nos conduzir com a coleta e a análise dos dados. A fim de, propor duas metodologias viáveis para possibilitar o aprofundamento e compreensão do principal objeto de estudo.

3.1 Metodologia usada para análise de madeira serrada

O presente estudo realizado por Almeida (2014) se constrói sobre o tema “classificação de tabuas de madeira usando processamento de imagens digitais e aprendizado de máquinas”, o estudo foi desenvolvido baseou-se em dois conjuntos de imagens de madeira serrada de Pinus.

O primeiro conjunto, contava com 84 imagens de tabuas de madeira serrada Pinus taeda ⁵ com dimensões aproximadas de 200cm de comprimento, por 2,0cm de espessura e larguras variando de 13,5 a 32,5cm, já o segundo o conjunto foi formado por 150 imagens de madeira serrada de Pinus elliottii, ⁶ com dimensões aproximadas de 250cm de comprimento, por 2,5cm de espessura e larguras variando de 12,0 a 30,5cm.

⁵ O Pinus taeda é uma das espécies florestais mais cultivadas no Brasil. Suas mudas são usadas em produtos de madeira sólida assim como para a produção de celulose. É um dos mais versáteis e de mais rápido crescimento.

⁶ O Pinus elliottii é uma espécie de pinheiro, no Brasil se localiza nas Regiões Sudeste e Sul. É uma árvore de crescimento rápido, de grande porte.

Figura 4 - Imagem de madeira serrada de Pinus Taeda



Fonte: Almeida 2014

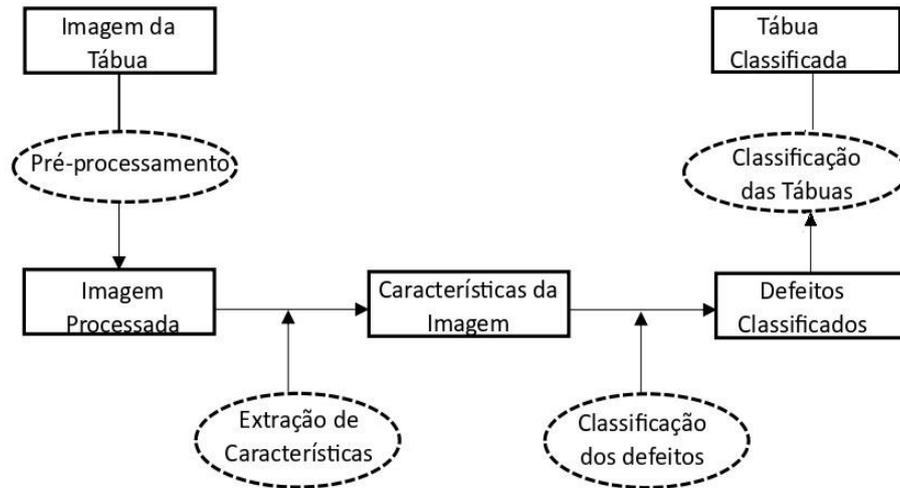
Figura 5 – imagem de madeira serrada de Pinus elliottii



Fonte: Almeida 2014

Para a realização desse estudo o autor, seguiu um fluxo de etapas, representado na figura 6, a primeira etapa consiste na obtenção de imagens das tabuas, capturadas a partir de câmeras fotográficas.

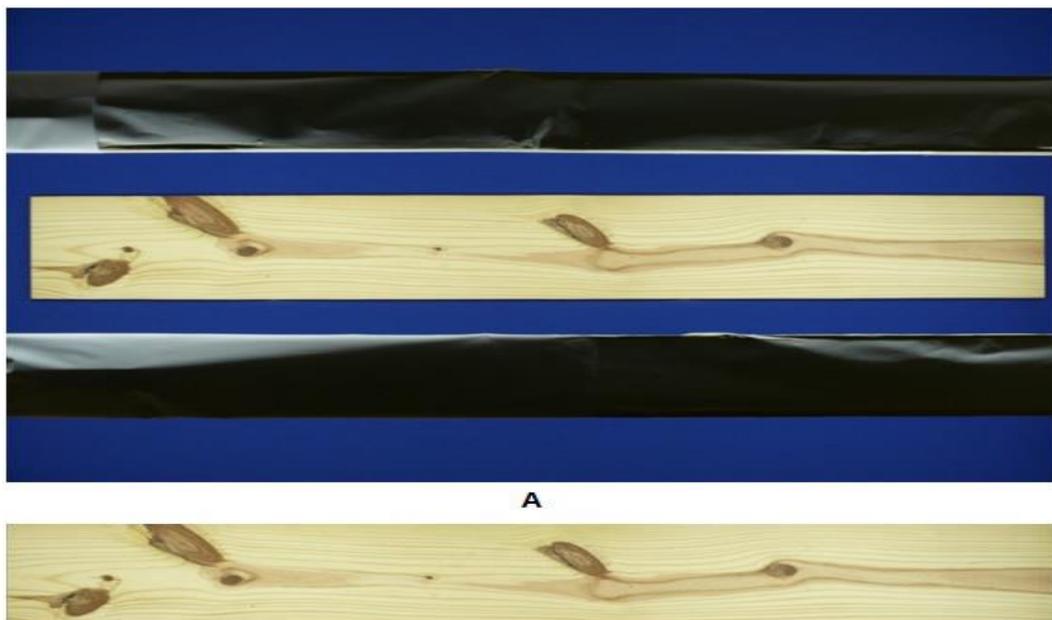
Figura 6 – Fluxo dos processos implementados no sistema de classificação de tábuas de madeira serrada de coníferas.



Fonte: Almeida 2014

Durante o desenvolvimento do estudo, foi utilizada um software dedicado à manipulação de imagens de madeira. Essa aplicação viabiliza a abertura de imagens para visualização, efetua a remoção de fundo, segmenta a imagem em blocos menores e realiza a remoção de características. Após a etapa de pré-processamentos foi disponibilizado uma gama de blocos de imagens para treinamento e teste das RNAs, conforme ilustrado na figura 7.

Figura 7 - Imagem ilustrativa do processo de remoção do fundo: A) Imagem original; B) Imagem sem o fundo.



Fonte: Almeida 2014

A partir da remoção do fundo as imagens foram fragmentadas e divididas em blocos de imagens com 128x128, 64x64 e 32x32 pixels. Os blocos de imagem foram usados para determinar os componentes da imagem e definir suas características.

Figura 8 - blocos de 128x128 pixels das tábuas.



Fonte: Almeida 2014

Figura 9 - blocos de 64x64 pixels das tábuas.



Fonte: Almeida 2014

Figura 10 - blocos de 32x32 pixels das tábuas.

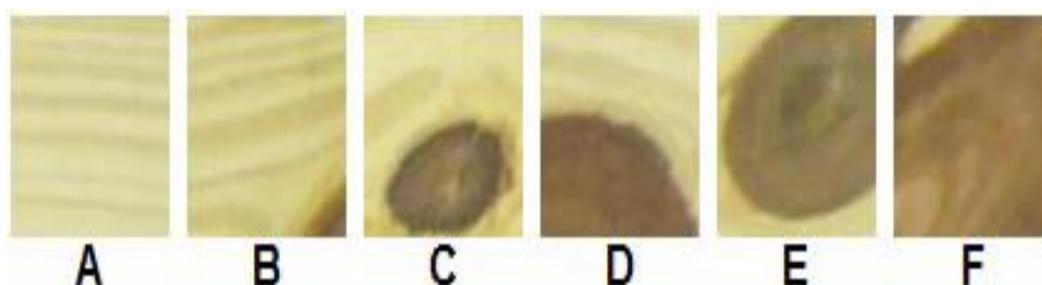


Fonte: Almeida 2014

Após este processo, os blocos passam por um processo de extração de características, paralelamente é realizada uma análise manual, para auxiliar o treinamento das Redes Neurais, criando classes de imagens com diferentes taxas de ocupação de defeitos na imagem, ilustrado na figura 11. Uma imagem limpa era classificada como L1, já imagens com presença de alguma imperfeição foi

classificada de 1 a 5, como N1, N2, N3, N4 e N5 dependendo da taxa ocupação do defeito, como mostra a Tabela 1.

Figura 11 - imagens dos blocos de 64x64 pixels das classes L1, N1, N2, N3, N4 e N5, respectivamente



Fonte: Almeida 2014

Tabela 1 – Dados das classes que foram definidas para a realização do treinamento usando aprendizado RNA MLP

Número	Classe	Referência
1	L1	Limpa
2	N1	Nó < 25 %
3	N2	Nó ≈ 25 %
4	N3	Nó ≈ 50 %
5	N4	Nó ≈ 75 %
6	N5	Nó > 75 %

Fonte: Almeida 2014

Os blocos de imagens também foram divididos em 4 grupos, o conjunto de imagens do Grupo 1, foi composto por 253 imagens de 128x128 pixels, selecionados aleatoriamente, apresentando um desequilíbrio significativo entre as classes. A classe L1 (Limpa) foi a mais representada, com 75 exemplares, enquanto a classe N5 (Nó > 75%) teve apenas 8 exemplares.

Já o Grupo 2, foi composto por 138 imagens de 128x128 pixels, a abordagem foi realizada apenas com duas classes. Foram escolhidas as classes L1 (Limpa) e N2 (Nó ~25%), sendo respectivamente 77 exemplares e 61 exemplares.

O Grupo 3, foi constituído por 240 imagens de 64x64 pixels, distribuiu igualmente 40 imagens entre as 6 classes. Por sua vez o Grupo 4, foi composto por

240 imagens de 32x32 pixels e mantendo o mesmo balanceamento de classes do grupo anterior.

3.2 Metodologia usada para análise de uma linha de produção de caixas

Com intuito de melhoria na realização de inspeção automática de caixas em uma esteira transportadora, foi empregado o modelo IA usados para reconhecimento padrão, Redes Neurais Artificiais (RNAs) que se destaca por sua capacidade de tolerância a falhas de acordo com Mohanan et al. (2016). A primeira etapa consiste em obter imagens do produto através da câmera Logitech HD Webcam C270, com resolução máxima de 1280x960.

Figura 12- Fluxo para a inspeção de caixas



Fonte: Martins et al (2018)

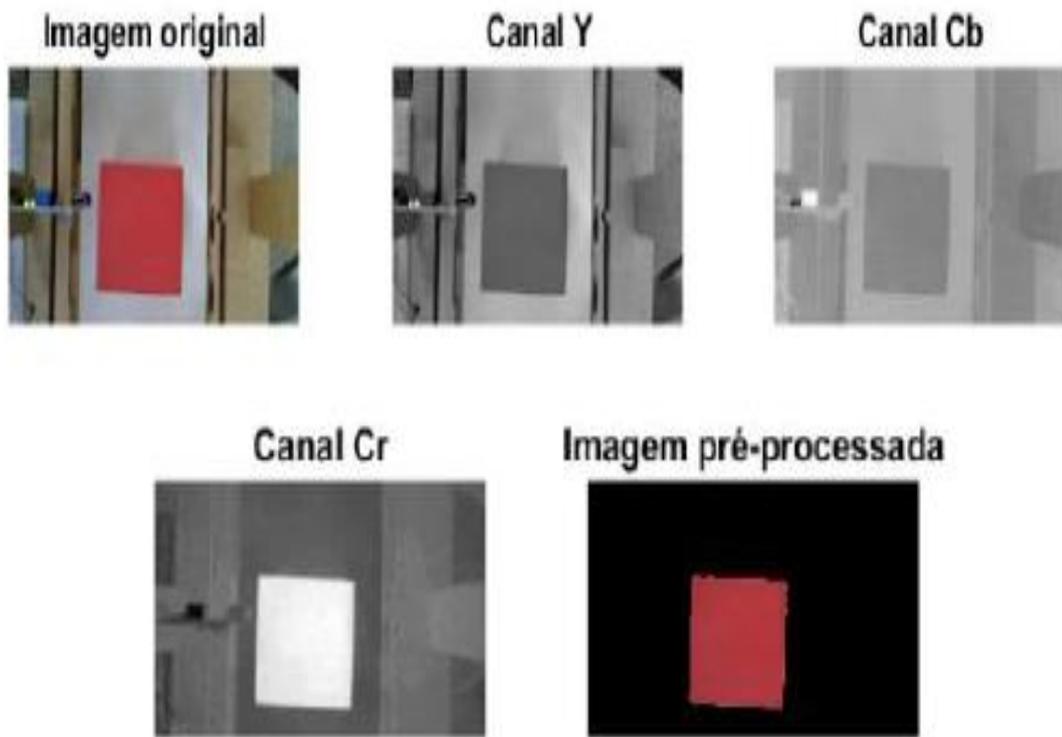
O processo se inicia pela captura da imagem através do sistema de cores RGB (*Red, Green e Blue – vermelho, verde e azul*) em que essas três cores são mescladas de diversas maneiras a por forma a um largo espectro cromático que é uma referência de imagens produzidas pelas câmeras digitais. (Gonzalez, 2003). Assim então, o sistema RBG é convertido para o sistema YCbCr que representa respectivamente (Y) Luminância, (Cb) Crominância azul e (Cr) a Crominância vermelha, onde faz-se favorável, visto que o sistema visual humano é mais sensível a luminância (Y).

Essas características são importantes para etapa de segmentação, que irá identificar e extrair o objeto para assim retirar o fundo da imagem, através do método Otsu's obtendo um limiar global que atua como uma barreira delimitando o espaço preenchido pela caixa e o fundo da imagem. Em seguida, para a fase de melhoramento é eliminado os ruídos vindos da etapa de segmentação, onde os

pixels são substituídos pela mediana da vizinhança 5x5 produzindo imagens de maior qualidade. (Martins et al 2018)

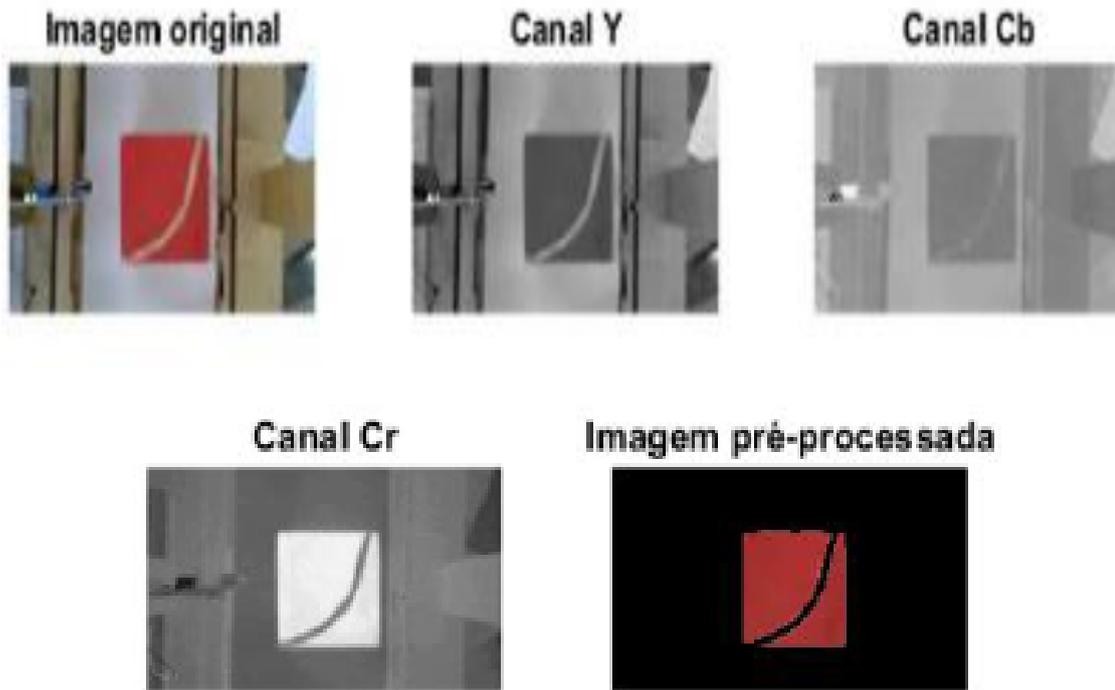
Após a etapa de segmentação e de melhoramento é exposto o resultado de duas imagens

Figura 13- Pré processamento de imagem de uma caixa sem defeito



Fonte: Martins et al (2018)

Figura 14- Pré processamento de imagem de uma caixa com defeito



Fonte: Martins et al (2018)

4.RESULTADOS E ANÁLISES

4.1 Resultados do uso de RNA em uma Serralheria

As Redes Neurais Artificiais Multilayer Perceptrons (RNAs MLP) foram treinadas conforme a classificação baseada na presença de defeitos. Dessa forma, os classificadores foram desenvolvidos para categorizar uma imagem como sendo livre de defeitos (L1) ou apresentando especificações específicas de nós, especificações em cinco categorias (N1, N2, N3, N4 e N5), conforme detalhado na Tabela 1, também foram utilizados os mesmos 4 grupos já descritos da seção 3.1.

Durante o processo de treinamento, foram realizados entre 500 e 2000 ciclos, com a validação sendo conduzida em 15% dos exemplos de treinamento. Ao aplicar o classificador às imagens de teste, os resultados obtidos foram documentados na Tabela 2.

Tabela 2 – Grupos usados para o processo de treinamento usando RNA MLP.

Grupo	Bloco de Imagens (pixels)	Quantidade total	Quantidade de imagens para treinamento	Quantidade de imagens para teste	Taxa de certos
1	128x128	253	172	81	86,42%
2	128x128	138	93	45	97,78%
3	64x64	240	162	78	93,59%
4	32x32	240	162	78	91,03%

Fonte: Almeida 2014 (Adaptada pelos autores)

Para o Grupo 1 de imagens (128x128 pixels), já descritos no item 3.1. O modelo gerado obteve uma taxa de acerto de 86,42% sobre as imagens de teste, o que corresponde à correta classificação de 70 dos 81 exemplares, esse desequilíbrio impactou os padrões no processo de treinamento do modelo.

Para o Grupo 2 de imagens, já descritos no item 3.1. O modelo gerado obteve uma taxa de acerto de 97,78% sobre as imagens de teste, o que corresponde à correta classificação de 44 dos 45 exemplares. O resultando de aproximadamente 98% de acertos foi o melhor do que nos testes realizados com o Grupo 1.

Para o Grupo 3 de imagens (64x64 pixels), já descritos no item 3.1. O modelo gerado alcançou uma taxa de acerto de 93,59% nas imagens de teste, resultando na classificação correta de 73 dos 78 exemplares. Apresentando um resultado também maior que o obtivo pelo Grupo 1. Acredita-se que essa capacidade se deve, principalmente, à quantidade total de exemplos: as Redes Neurais Artificiais (RNAs) demonstram uma capacidade superior de adaptação quando lidam com problemas que envolvem um menor número de exemplos, conforme destacado nos experimentos prolongados por Ashour et al (2008).

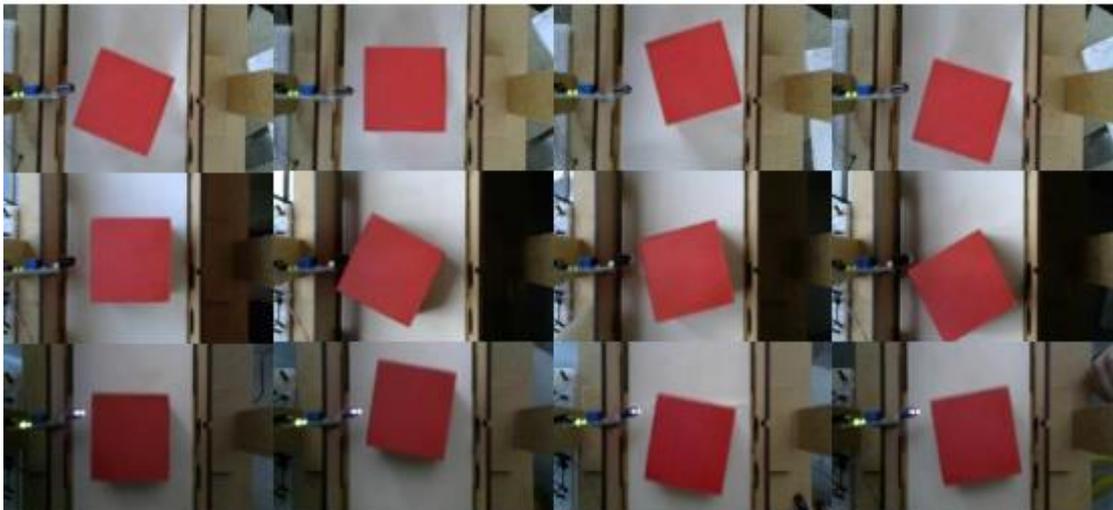
Para o Grupo 4 de imagens (32x32 pixels), já descritos no item 3.1, o modelo alcançou uma taxa de acerto de 91,03% nas imagens de teste. Isso corresponde à classificação correta de 71 dos 78 exemplares, demonstrando um desempenho semelhante aos obtidos no Grupo 3, apesar da redução na resolução das imagens.

4.2 Resultados do uso de RNA em caixas em uma linha de produção

Martins et al (2018), em sua pesquisa realizou teste em redes Neurais artificiais para detecção de defeitos em caixas numa esteira de produção automatizada.

Para essa análise foi utilizada, 430 imagens de caixa com defeito e de caixa sem defeito, ambas com formato de um cubo com arestas de 3,5cm, em diferentes ângulos e iluminações. A caixa com defeito apresenta imperfeição na pintura. A imagem 15 representa caixas com ausência de defeitos, já a imagem 16, exibe algumas imagens de caixa com defeito na pintura.

Figura 15 - Ausência de defeitos em caixas



Fonte: Martins et al (2018)

Figura 16 - Presença de defeitos na pintura das caixas



Fonte: Martins et al (2018)

As imagens obtidas foram separadas entre treinar, validar e teste a RNA, sendo 65%, para treino, 15%, para validar e 20% utilizadas para testar a RNA.

A Tabela 3 apresenta as taxas de acertos e erros da Rede Neural Artificial (RNA) nos conjuntos de dados de treinamento, validação e teste. É observado que a RNA obteve um desempenho de 100% em todos os conjuntos, demonstrando sua capacidade eficaz na classificação de imagens de caixas, distinguindo com precisão entre defeituosas e não defeituosas. Com base nesses resultados, podemos concluir que a metodologia proposta demonstra eficácia na tarefa de classificar caixas em uma esteira transportadora, identificando com precisão sua condição de defeito ou não defeito

Tabela 3 - Porcentagem de classificações corretas e incorretas da Rede Neural Artificial

Dados	Classificações corretas	Classificações incorretas
Treino	100%	0,00%
Validação	100%	0,00%
Teste	100%	0,00%

Fonte: Martins et al (2018)

4.3 Análise

Desse modo, os dados foram coletados através de dois sistemas diferentes, explorando de maneira abrangente o emprego de Redes Neurais Artificiais (RNAs) como ferramenta fundamental no contexto do controle de qualidade em uma linha de produção. Analisando os resultados obtidos pelo estudo de caso abordado no tópico 4.1 e 4.2 em confronto ao objetivo do artigo, revela que a utilização de RNAs, reflete em contribuições significativas para a eficiência e a confiabilidade do controle de qualidade, especialmente quando se trata de processos industriais utilizando imagens digitais.

A aplicação das RNAs na classificação de produtos defeituosos entrega resultados promissórios, evidenciando taxas de assertividade impressionantes em diferentes cenários. A capacidade adaptativa dos RNAs diante de conjuntos variados de imagens digitais ressalta suas características e robustez em lidar com desafios complexos associados à detecção de defeitos em uma diversidade de produtos.

O estudo realizado pelo Almeida (2014) sobre a classificação de tábuas de madeira serrada revelou uma média de assertividade de 90,95%, nos testes, já apresentados no tópico 4.1, trazendo um potencial significativo para a implementação dessas tecnologias em ambientes de controle de qualidade de produção de madeira.

A eficácia excepcional das RNAs na detecção de defeitos em caixas em uma rotina de produção automatizada, por Martins et al (2018), com uma taxa de assertividade de 100%, já apresentadas no tópico 4.2, ressalta não apenas a precisão, mas também a rapidez e eficiência desse método, proporcionando benefícios tangíveis em termos de redução de custos e aumento da eficiência operacional.

Como considerações finais, este estudo destaca a relevância das RNAs como uma ferramenta inovadora e indispensável para aprimorar os processos de controle de qualidade em linhas de produção na Indústria 4.0. À medida que a indústria avança na direção à automação e integração de tecnologias avançadas, a implementação estratégica de RNAs promete desempenhar um papel crucial na

otimização e na eficácia dos sistemas de controle de qualidade, contribuindo para um ambiente de produção mais eficiente e preciso, diminuindo desperdícios por falhas, otimizando os processos de fabricação.

5.CONCLUSÃO

Esse trabalho propôs conhecimento em relação a viabilidade em aplicar o conceito de Redes Neurais Artificiais para reconhecer defeitos em objetos por meio de imagens digitais. Os dados aqui apresentados, ressaltam a praticabilidade dessa técnica através de dois sistemas diferentes, explorados de maneira abrangente.

Considerando os resultados das pesquisas mencionadas acima neste estudo, nos tópicos 3.1 e 3.2, podemos assegurar a eficácia das Redes Neurais Artificiais (RNAs) para classificação de objetos. O trabalho conduzido por Almeida (2014) sobre a classificação de tábuas de madeira serrada revelou uma média na taxa de assertividade de 90,95% nos testes nos 4 grupos, conforme apresentado no tópico 4.1, separadamente. Esses resultados evidenciam um potencial significativo para a aplicação dessas tecnologias em ambientes de controle de qualidade na produção de madeira

A detecção de defeitos em caixas em uma rotina de produção automatizada, por Martins et al (2018), com uma taxa de assertividade de 100%, já apresentadas no tópico 4.2, ressalta não apenas a precisão, mas também a rapidez e eficiência desse método, o que propõe a utilização desse método contribuiu para a confiabilidade da empresa em evitar falhas e custos adicionais devido a classificação das caixas defeituosas e não defeituosas.

Cumprindo com o propósito da pesquisa, certamente as amostras se mostraram uma excelente base de dados para trabalhos com uma RNA proporcionando além da conclusão uma possibilidade para o desenvolvimento de novos projetos, que possam contribuir com o avanço científico e tecnológico.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, O. C. P. Classificação de Tábuas de Madeira Usando Processamento de Imagens Digitais e Aprendizado de Máquina. 105f. Tese (Doutorado), Faculdade de Ciências Agrônômicas de Botucatu – FCA-UNESP, 2014.

ANDRADE, Eduardo de. Classificação de Cores de Embalagens de Defensivos Agrícolas Utilizando Redes Bayesianas. 2013. 97 f. Dissertação (Pós-Graduação em Engenharia Elétrica) – Departamento de Engenharia Elétrica, Universidade Federal do Paraná, Curitiba, 2013

ASHOUR, M.; HUSSIN, M.; MAHAR, K. Supervised texture classification using several features extraction techniques based on ann and svm. In: Computer Systems and Applications, 2008.

BACKES, André Ricardo; JUNIOR, Jarbas Joaci de Mesquita Sá. Introdução à Visão Computacional Usando MATLAB. Rio de Janeiro: Alta Books Editora, 2016

BHATT, Ashutosh Kumar; PANT 2015, Durgesh. Automatic Apple Grading Model Development Based on Back Propagation Neural Network and Machine Vision, and Its Performance Evaluation. Ai & Society, London

BRITO, Eduardo. Qualidade Total. [Digite o Local da Editora]: Cengage Learning Brasil, 2015.

CAPIZZI, Giacomo et al 2016. A Novel Neural Networks-based Texture Image Processing Algorithm for Orange Defects Classification. International Journal of Computer Science & Applications.

FELICIANO, Flávio F.; SOUZA, Igor L de; LETA, Fabiana R 2010. Visão Computacional Aplicada à Metrologia Dimensional Automatizada: Considerações Sobre sua Exatidão.

FERREIRA, Rogério. Aprendizado profundo. Editora Saraiva,2021.

GARVIN, David A., Gerenciando a qualidade: a visão estratégica e competitiva, Rio de Janeiro: Quality mark, 2002.

GONZALES, C. Rafael., Woods, R. E., Eddins, Steven L. (2003) Digital Image Processing Using MATLAB.

KASABOV, Nikola K. Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering. Second Printing. Massachusetts Institute of Technology: A Bradford book, 1998.

KÖCHE, José C. Fundamentos de Metodologia científica 1997

MITCHELL, T.M. Machine Learning. New York: McGraw-Hill, 1997.

MARTINS, Ingrid et al 2018. Um estudo de caso de redes neurais artificiais para a detecção de objetos defeituosos numa esteira de produção automatizada.

MOHANAN, Neeraja et al 2016. A Brief Description of Pattern Recognition Techniques. Imperial Journal of

PESSOTA, Jorge Henrique. Sistema Especialista Aplicado à Inspeção da Qualidade Visual de Grãos de Feijão. 2013. 83 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Nove de Julho, São Paulo, 2013.

RUSSELL, Stuart J.; NORVIG, Peter. Artificial Intelligence: A Modern Approach. Malaysia; Pearson Education Limited, 2013.