

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO DE JOINVILLE
CURSO DE ENGENHARIA MECATRÔNICA

WILLIAM CHIOU ABE

ASPECTOS DE PROJETO E IMPLANTAÇÃO DE UM SISTEMA DE ANÁLISE DE
SOLDA UTILIZANDO VISÃO COMPUTACIONAL

Joinville
2023

WILLIAM CHIOU ABE

ASPECTOS DE PROJETO E IMPLANTAÇÃO DE UM SISTEMA DE ANÁLISE DE
SOLDA UTILIZANDO VISÃO COMPUTACIONAL

Trabalho de Conclusão de Curso apresentado como requisito parcial para obtenção do título de bacharel em Engenharia Mecatrônica no curso de Engenharia Mecatrônica, da Universidade Federal de Santa Catarina, Centro Tecnológico de Joinville.

Orientador: Dr. Benjamin Grando Moreira

Joinville
2023

RESUMO

Este trabalho aborda o tema da aplicação de visão computacional e redes neurais artificiais na análise de solda, visando superar as limitações dos métodos convencionais. O estudo explora os parâmetros da soldagem por resistência, discute os métodos de análise de solda existentes e propõe um sistema que integra redes neurais e visão computacional. Além disso, o trabalho aborda a integração do código Python com um Controlador Lógico Programável (CLP) usando o protocolo Ethernet/IP e faz referência a pesquisas similares no campo, destacando a relevância dessas tecnologias na melhoria da análise de solda. A comunicação entre o Python e CLP na integração foi realizado com sucesso e obteve uma acurácia geral de 85% na análise de solda, uma diferença de apenas 0,77% entre o modelo de treinamento e os dados de teste. Apesar do resultado satisfatório, o treinamento da rede neural foi realizado com baixo volume de imagens e pode alcançar níveis de acurácia mais altos quando treinadas com maior quantidade.

Palavras-chave: Análise de solda. Visão computacional. Automatização de processo de inspeção.

ABSTRACT

This work addresses the topic of applying computer vision and artificial neural networks in welding analysis, aiming to overcome the limitations of conventional methods. The study explores the parameters of resistance welding, discusses existing welding analysis methods, and proposes a system that integrates neural networks and computer vision. In addition, the work addresses the integration of Python code with a Programmable Logic Controller (PLC) using the Ethernet/IP protocol and refers to similar research in the field, highlighting the relevance of these technologies in improving welding analysis. The communication between Python and the PLC in the integration was successfully achieved, obtaining an overall accuracy of 85% in weld analysis, with a difference of only 0.77% between the training model and the test data. Despite the satisfactory result, the neural network training was conducted with a low volume of images and can achieve higher levels of accuracy when trained with a larger quantity.

Keywords: Welding analysis. Computer vision. Automation of inspection process.

LISTA DE FIGURAS

Figura 1 – Etapas de soldagem a ponto por resistência.	13
Figura 2 – Exemplo de Chisel Test.	15
Figura 3 – Exemplo de Peel Test.	16
Figura 4 – Representação das camadas de uma rede neural.	18
Figura 5 – Exemplo de uma Rede Neural Convolucional de dois estágios.	19
Figura 6 – Exemplo de matriz de confusão.	20
Figura 7 – Pinça de solda Obara.	25
Figura 8 – Chapas soldadas para teste.	26
Figura 9 – Exemplo da arquitetura da RNA.	27
Figura 10 – Função para conexão entre PLC e Python.	29
Figura 11 – Função de leitura da tag.	29
Figura 12 – Função de escrita da tag.	30
Figura 13 – Início do programa Ladder.	31
Figura 14 – Lógica do PVI.	31
Figura 15 – Lógica do Style.	32
Figura 16 – Lógica do AcquireImage e AcquireImageStatus.	32
Figura 17 – Lógica do Schedule.	32
Figura 18 – Lógica do MainCycleProcComp.	32
Figura 19 – Robô Fanuc R-2000iB.	35
Figura 20 – Diagrama de atividades da linha de produção.	36
Figura 21 – Processo de produção.	37
Figura 22 – Diagrama do fluxo de integração Python/CLP.	37
Figura 23 – Exemplos de pontos de solda em conformidade.	39
Figura 24 – Exemplos de pontos de solda sem conformidade.	39
Figura 25 – Exemplos de pontos de solda falsos negativos.	40
Figura 26 – Exemplos de pontos de solda falsos positivos.	40

LISTA DE TABELAS

Tabela 1 – Componentes da rede neural convolucional	18
Tabela 2 – Resumo dos trabalhos similares	24
Tabela 3 – Lista de Tags.	31
Tabela 4 – Resultado matriz de confusão.	38

LISTA DE ABREVIATURAS E SIGLAS

<i>CIP</i>	Control and Information Protocol
<i>CLP</i>	Controlador Lógico Programável
<i>CNNs</i>	Redes Neurais Convolucionais
<i>CPU</i>	Central Processing Unit
<i>IA</i>	Inteligência Artificial
<i>IP</i>	Internet Protocol
<i>IHM</i>	Interface Homem-Máquina
<i>ITA</i>	Instituto Tecnológico de Aeronáutica
<i>ODVA</i>	Open DeviceNet Vendor
<i>RNA</i>	Rede Neural Artificial
<i>VC</i>	Visão Computacional

SUMÁRIO

1	INTRODUÇÃO	9
1.1	Objetivo	10
1.1.1	Objetivo Geral	10
1.1.2	Objetivos Específicos	11
2	FUNDAMENTAÇÃO TEÓRICA	12
2.1	Soldagem a ponto por resistência	12
2.2	Parâmetros da soldagem por resistência e sua influência na qualidade da solda	13
2.3	Análise de solda convencional	14
2.3.1	Chisel test	14
2.3.2	Peel test	15
2.3.3	Limitações dos métodos convencionais de análise de solda	15
2.4	Visão computacional	16
2.5	Redes neurais artificiais	17
2.5.1	Rede Neural Convolucional	18
2.5.2	Processo de treinamento da rede neural	19
2.5.3	Validação de uma rede neural	20
2.5.3.1	Matriz de Confusão	20
2.6	Controlador Lógico Programável(CLP) e código Ladder	21
2.6.1	Protocolo de comunicação Ethernet/IP	22
2.7	Trabalhos Similares	23
3	MÉTODO	25
3.1	Fabricação dos corpos de prova	25
3.2	Desenvolvimento da Rede Neural	26
3.2.1	Arquitetura da rede neural	27
3.3	Conexão do código Python com o CLP	27
3.3.1	Código Python	28
3.3.2	Código Ladder	29
3.3.3	Tags	29
3.3.4	Lógica do programa	30
3.3.5	Troca de serviço de comunicação do protocolo Ethernet/IP	32
3.4	Teste Local de conexão e do Sistema Integrado	33
4	RESULTADOS	34
4.1	Fábrica da cliente	34

4.1.1	Funcionamento da linha de produção	34
4.2	Métricas de qualidade da rede neural	35
4.2.1	Treinamento da rede	36
4.3	Resultado da rede neural	38
4.3.1	Matriz de confusão	38
4.3.2	Qualidade da solda	39
5	CONCLUSÕES	41
	REFERÊNCIAS	42

1 INTRODUÇÃO

A soldagem em serviços de manutenção industrial é um processo que consiste na união de materiais, na maioria metais e suas ligas, por meio de fusão e solidificação dos materiais. A soldagem é essencial para a indústria, pois visa prolongar a vida útil de equipamentos, máquinas e estruturas garantindo a segurança e a integridade de quem as utiliza. Atualmente, é o método de união de materiais mais importante para as indústrias, desde fabricações microeletrônicas até estruturas de milhares de toneladas de peso (MARQUES, 2005).

Em indústrias automobilísticas, o método de união mais empregado é a soldagem a ponto por resistência (DEVARASIDDAPPA, 2014). Esse processo proporciona elevadas taxas de produção, graças à sua simplicidade, rapidez, viabilidade de automatização e robotização. O processo de soldagem é realizado na região sobreposta onde o calor é gerado por meio da resistência do material à passagem de corrente elétrica em um intervalo de tempo (BATISTA, 2011).

O controle de produção na indústria automobilística utiliza dois métodos convencionais de uso de ferramentas manuais. O chisel test, que consiste em verificar em determinados estágios da linha, se as chapas continuam unidas por meio de martelo e talhadeira para forçar a separação das juntas, e o peel test, que consiste no rompimento da junta soldada e mede o tamanho da lentilha formada de modo manual (WILLIAMS; PARKER, 2004).

A inspeção de solda manual visa analisar não apenas a qualidade, mas também a precisão e a capacidade de resistência do procedimento por um profissional qualificado que garanta a eficiência (DEVARASIDDAPPA, 2014). Porém, na produção industrial automobilística existe o desafio de inspecionar os pontos de solda em larga escala, visto que em uma carroceria encontra-se de 4000-6000 pontos (WILLIAMS; PARKER, 2004), sendo inadequada a verificação manual para a quantidade de pontos existentes em linha de produção.

Uma forma de resolver o problema é com adição de 30% de pontos de solda além do necessário (WILLIAMS; PARKER, 2004), visto que as inspeções tradicionais não promovem um controle amostral adequado, entretanto, há acréscimo no tempo de produção, no consumo de energia e no custo de manufatura. Uma solução eficiente para o problema é a automatização aliada à inteligência artificial para o reconhecimento de pontos de solda apropriados na produção.

A visão computacional é a ciência responsável pela extração de informações significativas de máquinas a partir de imagens capturadas por câmeras de vídeo, sensores, scanners, entre outros dispositivos. Pode-se considerar como uma ciência

recente visto que por volta da década de 1970 iniciaram os trabalhos de visão computacional aliada a inteligência artificial, porém apenas na década de 1990 ocorreu o aprofundamento dos trabalhos (MILANO; HONORATO, 2010).

Aplicações que utilizam visão computacional podem ser encontradas em diversas áreas, como física, biologia, indústria, forças armadas, entre outras. Coelho et al. (2020) apresentam a metodologia que possibilita utilizar a visão computacional para monitorar o grau de distorção de uma chapa no processo de soldagem, além do que, confirmam a possibilidade de monitoramento em tempo real e qualidade da visão computacional no trabalho.

As marcas de superfície de um ponto de solda são caracterizadas por sofrer alterações na dimensão, coloração e morfologia. Essas três classes permitem a obtenção de informações por meio de imagens do ponto de solda, que, por sua vez, são utilizados para constituir uma base de dados em diferentes condições de processo (SENA, 2019). Por fim, a análise é feita pelo treinamento de uma rede neural com esse banco de dados, possibilitando que novas imagens sejam apresentadas e classificadas quanto à qualidade.

Nessa perspectiva, pretende-se, a partir da identificação da influência de parâmetros de processo na formação do ponto de solda e dos atributos de superfície por visão de máquina adjunto a inteligência artificial, analisar sua relação com os parâmetros e fenômenos de processo, além de validar a eficiência dessa tecnologia no processo de produção, propondo um método de inspeção de pontos de solda automatizado com uso de visão computacional.

Para o desenvolvimento do estudo, o método é feito variando o parâmetro de corrente de soldagem para induzir diferentes efeitos na marca de superfície. Dessa forma, a indução de diferentes correntes permite avaliar os modos de falhas e expulsar o material na superfície de união e entre a capa do eletrodo e a chapa. Portanto, a fim de avaliar o método proposto, foi selecionado como parâmetro de estudo a corrente de soldagem.

1.1 OBJETIVO

Para resolver a problemática de tempo de produção, consumo de energia e custo de manufatura por conta da inspeção manual, propõe-se neste trabalho os seguintes objetivos.

1.1.1 Objetivo Geral

Este trabalho visa avaliar um sistema automatizado de inspeção de pontos de solda e implantá-lo em um processo fabril.

1.1.2 Objetivos Específicos

- Avaliar o sistema automatizado de inspeção de pontos de solda.
- Integrar o uso de sistema de inspeção de solda em um processo fabril.
- Descrever a implantação do sistema em uma planta.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo tem como finalidade explicar os princípios teóricos e técnicos que foram utilizados para realizar o trabalho como a soldagem a ponto por resistência, sistemas de Visão Computacional (VC), Redes Neurais Artificiais (RNA) e Controlador Lógico Programável (CLP). As seções iniciais apresentam os detalhes na área de soldagem e os testes da qualidade presentes na indústria, enquanto nas seções finais apresentam os aspectos na área de inovação com VC atrelada a Inteligência Artificial (IA).

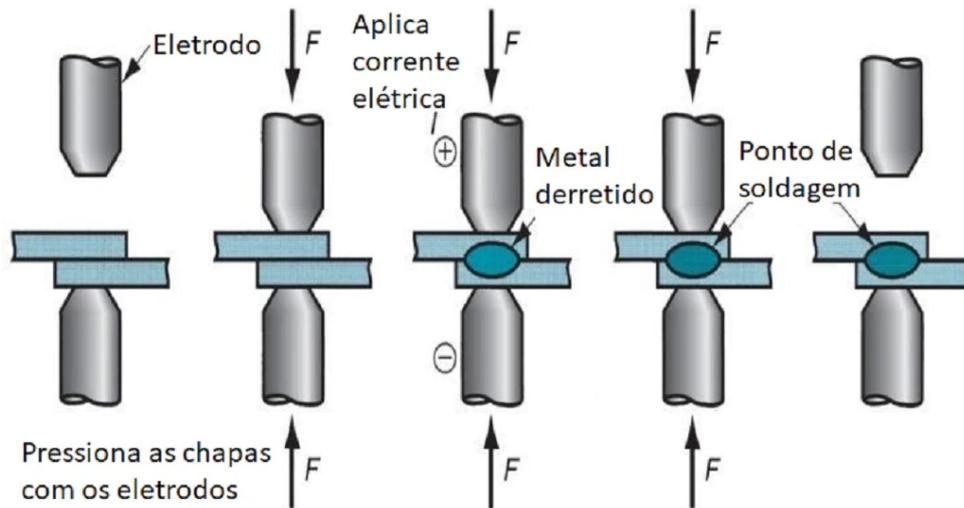
2.1 SOLDAGEM A PONTO POR RESISTÊNCIA

A soldagem a ponto por resistência é um processo no qual ocorrem fenômenos elétricos, térmicos, mecânicos e metalúrgicos gerando calor, por efeito Joule, devido à passagem de corrente elétrica através dos materiais e deve ser suficiente para fundir os metais utilizados (ZHANG; SENKARA, 2011). Os eletrodos garantem o contato adequado entre as chapas evitando a expulsão do metal líquido com a difusão do calor e são internamente refrigerados para não ocorrer a soldagem das capas de eletrodos na superfície da chapa (SENA, 2019).

O ciclo de soldagem é composto por quatro etapas básicas: compressão, soldagem, manutenção e espera como pode ser visto na Figura 1. A primeira consiste na aproximação dos eletrodos até iniciar a passagem de corrente elétrica, seguido da segunda fase que proporciona a ação dos efeitos térmicos almejando a formação da poça de fusão chamado de lentilha de forma que o tamanho seja adequado e resistente (SENA, 2019).

A terceira etapa é caracterizada desde o final da passagem de corrente elétrica até o afastamento total dos eletrodos conhecida como etapa de manutenção. A última etapa do processo consiste no tempo de espera para retirada das chapas com a junta soldada até o posicionamento de novas chapas da linha. Essas etapas do processo influenciam a microestrutura final do ponto de solda juntamente com a escolha dos materiais, a força aplicada e resfriamento do sistema (SENA, 2019).

Figura 1 – Etapas de soldagem a ponto por resistência.



Fonte: Adaptado de Enami, Farahani e Sohrabian (2016, p. 2).

A composição química do metal é um fator importante para a microestrutura final juntamente com a magnitude de força aplicada que afeta as resistências interfaciais, podendo dificultar ou facilitar a passagem de corrente elétrica alterando o calor gerado no ponto (ZHANG; SENKARA, 2011). Além disso, o ponto em que os eletrodos permanecem em contato após o término da passagem de corrente, influi na taxa de resfriamento do material e, por conseguinte, na microestrutura resultante (SENA, 2019).

2.2 PARÂMETROS DA SOLDAGEM POR RESISTÊNCIA E SUA INFLUÊNCIA NA QUALIDADE DA SOLDA

Os parâmetros de processo desempenham um papel crucial na determinação da qualidade da solda. Os parâmetros mais influentes são a corrente de soldagem, o tempo de passagem de corrente e a força aplicada pelos eletrodos. Esses parâmetros influenciam diretamente o aporte térmico fornecido ao sistema e são responsáveis pelo crescimento da lentilha de solda, cujo tamanho é rotineiramente utilizado para correlação com a resistência mecânica da junta (SENA, 2019).

A corrente elétrica é o parâmetro mais relevante no processo, sendo o mais influente na formação do ponto de solda. Juntamente com o tempo de atuação, essas duas variáveis induzem diferentes tamanhos de lentilha e regimes de aquecimento e resfriamento, podendo gerar maiores lentilhas de solda até que a condição de indentação excessiva, ou expulsão sejam atingidas. A taxa de resfriamento pode induzir diferentes tipos de microestruturas resultantes, conforme a composição química dos metais soldados (SENA, 2023, p. 22).

2.3 ANÁLISE DE SOLDA CONVENCIONAL

Os métodos mais comuns para a análise de solda incluem inspeção visual, ensaios mecânicos e técnicas de medição. A inspeção visual é um método simples e amplamente utilizado, mas é altamente subjetiva e pode não detectar todas as falhas na solda. Os ensaios mecânicos, como o ensaio de tração e dobramento, são mais precisos, mas podem danificar a peça e só podem ser realizados em uma pequena quantidade de amostras. As técnicas de medição, como a ultrassonografia e a radiografia, são úteis para detectar defeitos internos na solda, mas são caras e demoradas.

É válido ressaltar a importância nas limitações de cada método para escolher o mais adequado para cada situação. Atualmente os métodos utilizados são os ensaios mecânicos pois alcançam uma maior precisão e um custo menor, os mais utilizados são o *Chisel test* e o *Peel test*.

2.3.1 Chisel test

O *Chisel test* é uma das técnicas destrutivas mais comum nas indústrias pois diversas medidas podem ser tomadas em relação ao resultado desse teste como o diâmetro da solda, recuo da chapa, circularidade do ponto de solda, modo de falha e evidência da expulsão de metal líquido. O inspetor realiza batidas com talhadeira e martelo entre as chapas soldadas até a falha e infere a qualidade da junta soldada e o estado do processo, porém quando há falhas por diferentes modos, a análise torna um desafio para o inspetor sendo preferível outro tipo de teste para esse caso (SUMMERVILLE; COMPSTON; DOOLAN, 2019).

Figura 2 – Exemplo de Chisel Test.



Fonte: Na, Jeong-Kwan (2012)

2.3.2 Peel test

Assim como o *Chisel test*, o *Peel test* também é uma técnica destrutiva ao aplicar uma força de tração perpendicular ao plano da junta soldada, separando as partes unidas e medindo o tamanho da lentilha. É comum utilizar um microscópio óptico ou eletrônico de varredura para obter imagens ampliadas da superfície da junta e realizar a medição da lentilha com o auxílio de software especializado. A partir dessa medida, é possível avaliar a qualidade da solda e verificar se ela está dentro dos padrões exigidos pela norma técnica aplicável. O *Peel test* é amplamente utilizado em processos de controle de qualidade, pesquisa e desenvolvimento de novos materiais e técnicas de soldagem (SENA, 2019).

2.3.3 Limitações dos métodos convencionais de análise de solda

Apesar dos métodos serem comumente utilizados no dia a dia eles possuem limitações, como a subjetividade na inspeção visual e a falta de precisão dos ensaios mecânicos e técnicas de medição. Além disso, esses métodos podem não detectar todas as falhas na soldagem, especialmente em casos de defeitos internos. É

Figura 3 – Exemplo de Peel Test.



Fonte: RAJALAKSHMI;SHAFIQ (2017)

importante ressaltar que, para garantir a qualidade da solda, muitas vezes é necessário realizar inspeções manuais adicionais (Alusolda, 2023).

Outro fator importante está relacionado à segurança dos operadores nos métodos atuais de análise de solda visto que os trabalhadores são expostos a maiores riscos, uma vez que ficam próximos das fontes de calor e dos produtos químicos envolvidos na soldagem (Alusolda, 2023).

Um estudo de revisão sobre técnicas de análise de soldagem, realizado por (MODENESI, 2001), destaca que a inspeção visual é um método subjetivo e que a análise por ensaios não destrutivos é limitada a detecção de defeitos superficiais. O estudo também resalta que a análise por ultrassom e radiografia pode ser utilizada para detectar defeitos internos, mas que a interpretação dos resultados continua sendo subjetiva.

2.4 VISÃO COMPUTACIONAL

A visão computacional é uma ciência responsável pela visão de uma máquina, ou seja, como um computador percebe o ambiente ao seu redor, extraindo informações significativas de imagens capturadas por câmeras de vídeo, sensores, scanners, entre outros dispositivos. Essas informações permitem reconhecer, manipular e pensar sobre os objetos que compõem uma imagem (MILANO; HONORATO, 2010).

A visão computacional fornece ao computador uma infinidade de informações

a partir de imagens e vídeos, permitindo que o computador execute tarefas inteligentes, simulando e aproximando-se da inteligência humana. Na década de 70, os primeiros trabalhos de visão computacional aliados à inteligência artificial começaram, e na época, acreditava-se que em pouco tempo seria possível representar completamente o sentido da visão em uma máquina. No entanto, com o desenvolvimento de novas pesquisas nas décadas subsequentes, verificou-se uma complexidade muito maior do que inicialmente imaginado, principalmente devido à falta de informações e modelos que representassem como as imagens são interpretadas no cérebro humano (MILANO; HONORATO, 2010)

A visão computacional tem aplicações em diversas áreas, como física, biologia, indústria, forças armadas, entre outras. No contexto da soldagem industrial, a visão computacional é aplicada para medição e análise da seção transversal de chapas metálicas unidas pelo processo de soldagem.(MARTINS; JUNIOR, 2011)

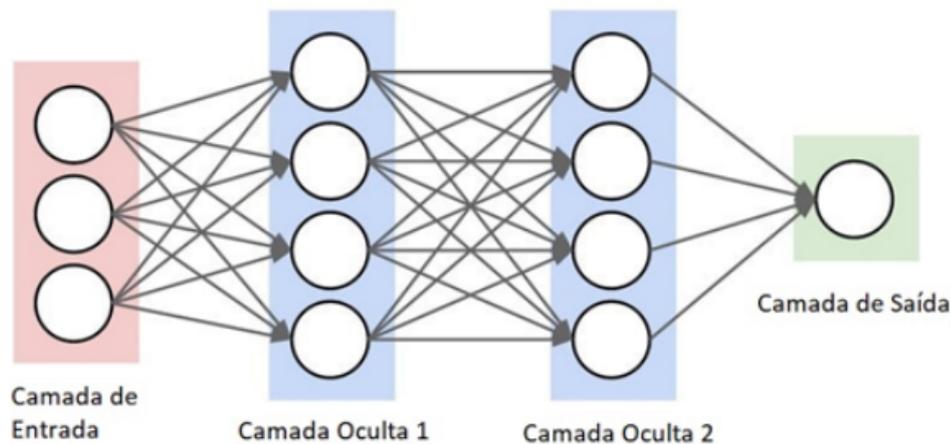
2.5 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais(RNA) são umas das principais ferramentas utilizadas no aprendizado de máquinas. O sistema neural é inspirado no cérebro e se destina a replicar a maneira como os humanos aprendem e consiste de camadas de entrada, saída e, na maioria dos casos, uma camada oculta que interliga essas camadas (BERTONI; FEDER, 2018b). As aplicações com RNA são ideais em casos de detecção de padrões complexos ou numerosos para o usuário.

Apesar da RNA existir desde os anos 1940, apenas na última década se tornou uma parte importante da inteligência artificial, o que se deveu ao fato de uma técnica chamada retropropagação, que permite que as redes ajustem as camadas ocultas em situações em que o resultado foi diferente do esperado. Além disso, o aparecimento do deep learning permitiu que diferentes camadas de uma rede extraíam diferentes características, favorecendo o reconhecimento de um resultado previsto (BERTONI; FEDER, 2018b), como pode ser visto na Figura 4.

Cada camada oculta pode analisar diferentes elementos para compor o resultado e quando atingem determinada quantidade de camadas, a rede de aprendizagem cria detectores de recursos complexos. Feito isso, os pesquisadores que treinaram a rede podem usar a retropropagação para corrigir os erros cometidos, com o que a rede poderá realizar suas próprias tarefas sem a necessidade intervenção humana (BERTONI; FEDER, 2018b). Existem diversas técnicas de redes neurais como Rede Neural Feedforward, rede neural recorrente , Rede Adversarial Generativa, entre outras. Uma dessas técnicas é a Rede Neural Convolucional que será apresentado a seguir.

Figura 4 – Representação das camadas de uma rede neural.



Fonte: Adaptado de Musiol (2016, p. 1)

2.5.1 Rede Neural Convolucional

As Redes Neurais Convolucionais (CNNs) são uma técnica que pode ser utilizada para classificação de imagens. Elas usam filtros para analisar os pixels de uma imagem e aprender características importantes para a classificação. As CNNs são compostas por três componentes principais que podem ser vistos na Tabela 1.

Tabela 1 – Componentes da rede neural convolucional

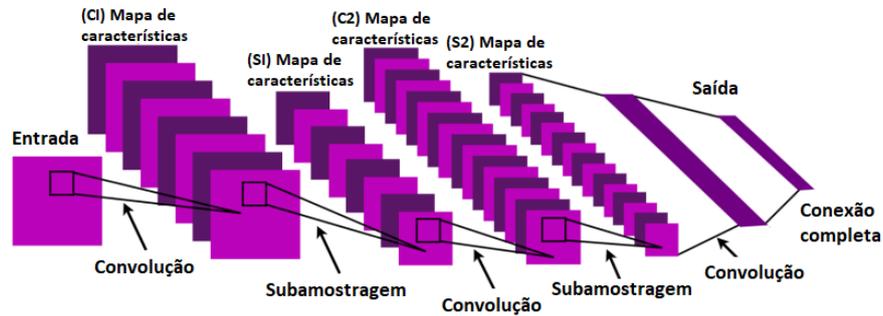
Camadas Convolucionais	Aplicam filtros à imagem e realizam cálculos para produzir um mapa de características. Elas também aplicam uma função chamada ReLU para adicionar complexidade ao modelo (BERTONI; FEDER, 2018b).
Camadas de agrupamento	Reduzem a quantidade de informação do mapa de características para tornar o processamento mais eficiente. O método mais comum é o "pooling máximo", que mantém apenas o valor mais importante de cada área do mapa (BERTONI; FEDER, 2018b).
Camadas densas	Usam as características extraídas para classificar a imagem. Todos os nós nesta camada estão conectados a todos os nós da camada anterior (BERTONI; FEDER, 2018b).

Fonte : Autor (2023)

Uma CNN típica é estruturada em estágios e composta por várias camadas convolucionais e de agrupamento, seguidas por uma ou mais camadas densas que fazem a classificação final. A última camada densa tem um nó para cada categoria possível que o modelo pode prever, e usa uma função chamada softmax para dar a cada nó um valor entre 0 e 1. Esses valores podem ser interpretados como a probabilidade da imagem pertencer a cada categoria (BERTONI; FEDER, 2018a). A Figura 5 mostra

um exemplo de uma CNN de dois estágios.

Figura 5 – Exemplo de uma Rede Neural Convolutiva de dois estágios.



Fonte: Adaptado de LECUN; KAVUKCUOGLU; FARABET (2010)

Cada estágio de uma CNN recebe um conjunto de mapas de características como entrada. Um mapa de características é basicamente uma representação que destaca certas características da imagem. Por exemplo, se a CNN está processando uma imagem colorida, a entrada do primeiro estágio seria os três canais de cores da imagem (vermelho, verde e azul). Cada um desses canais de cores seria tratado como um mapa de características (JURASZEK et al., 2014).

A convolução é basicamente a aplicação de um filtro ao mapa de características. Cada filtro é projetado para destacar uma característica específica da imagem. Por exemplo, um filtro pode ser projetado para destacar linhas verticais, enquanto outro pode ser projetado para destacar linhas horizontais (JURASZEK et al., 2014).

2.5.2 Processo de treinamento da rede neural

Para a construção de modelos de aprendizado de máquina pode-se utilizar o treinamento das redes neurais. Ele consiste em apresentar um conjunto de dados de entrada para a rede neural, para que ela possa aprender a relacionar os dados de entrada com a saída desejada. Durante o treinamento, a rede neural ajusta seus pesos e bias para minimizar a diferença entre as saídas previstas e as saídas reais (RAUBER, 2005).

O processo é separado em três conjuntos: treinamento, validação e teste, para garantir que a rede neural esteja sendo treinada de forma adequada e não esteja sofrendo de *overfitting*. *Overfitting* é um fenômeno que ocorre quando um modelo de aprendizado de máquina se ajusta excessivamente aos dados de treinamento, resultando em um desempenho inferior em dados não vistos, como dados de validação ou teste (MONARD; BARANAUSKAS, 2003).

Dentre as técnicas utilizadas no treinamento de redes neurais, destaca-se o *backpropagation* que ajusta os pesos entre as camadas por meio da retropropagação

do erro encontrado em cada iteração, utilizados para atualizar os pesos e bias da rede neural (MATSUNAGA, 2012).

2.5.3 Validação de uma rede neural

Para avaliar a eficácia de modelos de aprendizado de máquina, é fundamental realizar a validação da rede neural e selecionar as métricas apropriadas para o problema e interpretá-las adequadamente. Neste trabalho foi utilizado a matriz de confusão para avaliar o desempenho de modelos de classificação, permitindo a análise de acertos e erros em cada classe.

Adicionalmente, existem diversas métricas de avaliação disponíveis para mensurar o desempenho de um modelo, como a acurácia, que mede a proporção de predições corretas, e a precisão e revocação, que mensuram a habilidade do modelo em classificar corretamente as classes positivas e negativas (RAMOS et al., 2018).

2.5.3.1 Matriz de Confusão

Uma matriz de confusão é uma tabela que é usada para avaliar o desempenho de um modelo de classificação. Ela mostra a frequência com que cada classe foi prevista corretamente ou incorretamente pelo modelo como pode ser visto na Figura 6. A matriz de confusão tem quatro células, que representam os seguintes valores (RAMOS et al., 2018):

- Verdadeiro Positivo (VP): quando a classe real é positiva e o modelo prevê corretamente como positiva.
- Falso Positivo (FP): quando a classe real é negativa e o modelo prevê incorretamente como positiva.
- Verdadeiro Negativo (VN): quando a classe real é negativa e o modelo prevê corretamente como negativa.
- Falso Negativo (FN): quando a classe real é positiva e o modelo prevê incorretamente como negativa.

Figura 6 – Exemplo de matriz de confusão.

		Classe Verdadeira (Referência)	
		Negativo	Positivo
Classe Predita (Modelo)	Negativo	VN	FN
	Positivo	FP	VP

Fonte: Ramos (2018)

Esses valores são usados para calcular várias métricas de desempenho do modelo, sendo as mais comumente utilizadas a precisão, revocação ou sensibilidade

e acurária para avaliar modelos de classificação. Cada uma dessas métricas fornece uma visão diferente da qualidade do modelo.

A precisão mede a proporção de instâncias classificadas corretamente como positivas (VP) em relação a todas as instâncias classificadas como positivas (VP+FP) (RAMOS et al., 2018). Em outras palavras, ela indica a taxa de verdadeiros positivos em relação ao total de instâncias classificadas como positivas e nenhum exemplo negativo é incluído (MATOS et al., 2009). A precisão pode ser obtida conforme demonstrado na Equação 1.

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (1)$$

O revocação, por sua vez, mede a proporção de instâncias classificadas corretamente como positivas em relação a todas as instâncias que realmente são positivas. Em outras palavras, ele indica a taxa de verdadeiros positivos em relação ao total de instâncias positivas presentes na base de dados (MATOS et al., 2009). O revocação é importante quando se deseja minimizar o número de falsos negativos. Por exemplo, se um modelo é usado para diagnosticar uma doença, é importante que o revocação seja alto, pois a identificação de casos verdadeiros como falsos negativos pode ter consequências graves na saúde do paciente (RAMOS et al., 2018). O revocação pode ser obtido de acordo com a Equação 2.

$$\text{Revocação} = \frac{VP}{VP + FN} \quad (2)$$

Já a acurácia é a proporção de instâncias classificadas corretamente em relação ao total de instâncias na base de dados. Ela é uma medida geral do desempenho do modelo e pode ser útil quando todas as classes têm a mesma importância ou quando o objetivo é maximizar o desempenho geral do modelo. No entanto, a acurácia pode ser enganosa em situações em que as classes são desequilibradas, ou seja, uma classe é muito mais frequente do que a outra. Nesses casos, um modelo pode ter uma acurácia alta simplesmente porque está prevendo corretamente a classe dominante e ignorando a classe minoritária (RAMOS et al., 2018). A acurácia é calculada por meio da Equação 3.

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3)$$

2.6 CONTROLADOR LÓGICO PROGRAMÁVEL (CLP) E CÓDIGO LADDER

Controladores Lógicos Programáveis (CLPs) são componentes fundamentais na automação de processos de manufatura. Eles permitem a automação de processos tanto discretos quanto contínuos permitindo otimizar a utilização de recursos e aumentar a produção. Os CLPs possibilitam a criação de sistemas de controle

flexíveis e confiáveis, que podem variar significativamente em termos de natureza e complexidade. Atualmente, é comum encontrar CLPs sendo utilizados como controladores independentes ou como parte de um sistema de manufatura integrado na indústria, com a linguagem Ladder sendo a mais utilizada para programar o CLPs (OLIVEIRA; BRAGA; ALMEIDA, 2010).

A linguagem Ladder é uma representação gráfica baseada em circuitos de relé. Sua facilidade de manipulação, interpretação e representação de conexões físicas entre componentes (como sensores e atuadores) a torna amplamente utilizada em contextos industriais. Existem vários dialetos de Ladder na indústria, como os desenvolvidos por Siemens (2004) e Ridley (2004), cada um adaptado para um Controlador Lógico Programável (CLP) específico. Esses dialetos possuem suas próprias funções e pequenas variações visuais, mas todos seguem o padrão IEC. A execução do CLP ocorre em ciclos de varredura. Durante um ciclo, a energia flui da esquerda para a direita e de cima para baixo, passando por cada degrau do diagrama sequencialmente. Quando a energia chega ao final do diagrama ou o tempo do ciclo termina, o ciclo recomeça. Cada degrau do diagrama representa uma instrução do programa (OLIVEIRA et al., 2011).

O código Ladder é composto por uma série de símbolos que representam contatos (inputs) e bobinas (outputs). Os contatos podem ser normalmente abertos ou normalmente fechados, representando as condições de entrada, enquanto as bobinas representam as saídas (OLIVEIRA et al., 2011). Essas entradas e saídas, assim como outras variáveis dentro do programa, são rotuladas ou nomeadas para que o código se torne mais legível e fácil de entender, conhecida como tags. As tags permitem que os programadores usem nomes significativos para representar diferentes elementos do sistema.

2.6.1 Protocolo de comunicação Ethernet/IP

Ethernet/IP (Ethernet Industrial Protocol) é um padrão de rede industrial aberto que suporta mensagem em tempo real e troca de mensagens. Ele opera utilizando o chip de comunicação padrão Ethernet e o mesmo meio físico, atuando como um protocolo de aplicação industrial projetado para uso em automação. Construída sobre os protocolos TCP/IP, esta interface utiliza hardware e software já estabelecidos para definir um protocolo de camada de aplicação para a configuração, acesso e controle de dispositivos de automação industrial (COUTO, 2010).

O protocolo Ethernet/IP categoriza nós de rede de acordo com tipos de dispositivos, conforme determinado por procedimentos específicos pré-estabelecidos. Seu protocolo de aplicação é baseado no *Control and Information Protocol* (CIP), que é também utilizado nas redes DeviceNet e ControlNet. Com base nesses protocolos, a Ethernet/IP fornece um sistema integrado que oferece transparência desde o ambiente

industrial, até a rede corporativa, conforme definido pela *Open DeviceNet Vendor Association*(ODVA)(COUTO, 2010).

2.7 TRABALHOS SIMILARES

Na busca por aprimorar a qualidade e eficiência dos processos de soldagem, diversos estudos têm explorado o uso de visão computacional e inteligência artificial. Essas tecnologias têm demonstrado grande potencial para melhorar a precisão das inspeções de solda, reduzir erros e aumentar a produtividade. Neste contexto, quatro trabalhos foram analisados, todos focados em aplicar essas técnicas avançadas para aprimorar diferentes aspectos do processo de soldagem.

O trabalho "Inspeção de Solda Utilizando Visão Computacional"(MARTINS; JUNIOR, 2011) propõe um sistema de visão computacional para medição e análise da seção transversal de chapas metálicas unidas sob a ação do processo de soldagem industrial. O sistema proposto demonstrou uma precisão de 94%, superando a eficácia das medições realizadas por operadores de soldagem.

Já o trabalho "Análise Inteligente de Modos de Transferência Metálica em Soldagem GMAW a partir de Visão Computacional"(SILVA et al., 2017) aplica métodos de processamento de imagem em imagens de soldagem para analisar a estabilidade, a qualidade e possíveis problemas de um processo de soldagem GMAW, demonstrando a eficácia dos algoritmos utilizados.

Por outro lado, o trabalho "Inspeção de qualidade de solda por visão computacional"(RIBEIRO et al., 2022) propõe a utilização de uma rede neural para a inspeção de qualidade no processo produtivo de soldagem. O sistema foi capaz de eliminar os resultados falsos positivos, e todos os erros identificados foram falsos negativos, ou seja, soldas boas acusadas como não satisfatórias.

Finalmente, o trabalho "Sistema de Visão Computacional para Soldagem Linear Automatizada de Chapas Chanfradas"(WEIS, 2018) propõe desenvolver um sistema de visão computacional para identificação e rastreamento de juntas em processos de soldagem e foi eficaz na identificação e rastreamento de juntas em processos de soldagem, com a maior média de erro na medição da junta sendo de 0,538 mm para a abertura superior do chanfro. Para uma melhor visualização, foi criada a Tabela 2 que apresenta os nomes dos trabalhos, autores e os resultados obtidos.

Tabela 2 – Resumo dos trabalhos similares

Nome do Trabalho	Resultado do Trabalho
Uso de um Sistema de Visão Computacional para Inspeção de Soldas	O sistema proposto mostrou uma precisão de aproximadamente 94% da análise de solda
Análise Inteligente de Modos de Transferência Metálica em Soldagem GMAW a partir de Visão Computacional	O algoritmo proposto conseguiu fazer reconhecimento dos modos de transferências através da medição do raio da gota e do eletrodo nas imagens
Inspeção de qualidade de solda por visão computacional	O sistema foi capaz de eliminar os resultados falsos positivos, e todos os erros identificados foram falsos negativos, ou seja, soldas boas acusadas como não satisfatórias
Sistema de Visão Computacional para Soldagem Linear Automatizada de Chapas Chanfradas	O sistema de visão computacional foi eficaz na identificação e rastreamento de juntas em processos de soldagem

Fonte: Autor (2023)

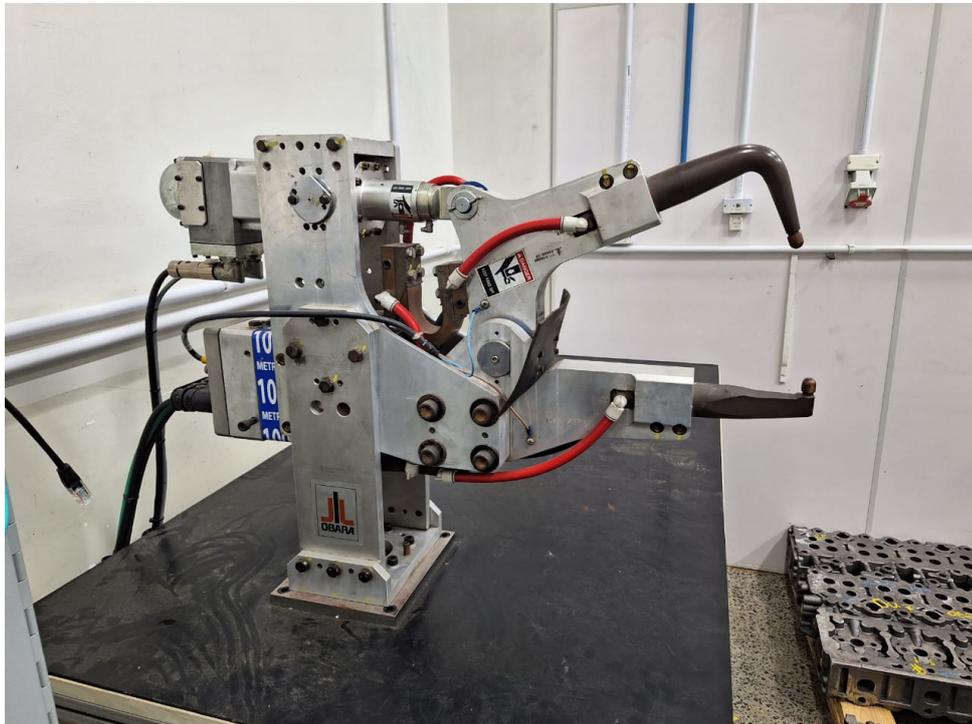
3 MÉTODO

Nesta seção de metodologia, descrevemos o processo de fabricação do corpo de prova, o treinamento da rede neural artificial e o desenvolvimento do programa no PLC e no Python. As etapas de fabricação dos corpos de provas e do treinamento da RNA foram realizadas no Instituto Tecnológico de Aeronáutica (ITA) no ano de 2019 por uma empresa de inovação tecnológica. Em 2022, foi iniciado o período de estágio nessa empresa no Senai de Joinville, realizando os testes e os códigos para conexão do CLP. Os códigos apresentados possuem alterações para preservar o sigilo industrial.

3.1 FABRICAÇÃO DOS CORPOS DE PROVA

A fabricação do corpo de prova foi realizada utilizando uma pinça de solda a ponto por resistência da marca Obara como pode ser vista na Figura 7. Ela permite o controle de tensão e corrente para realizar a solda.

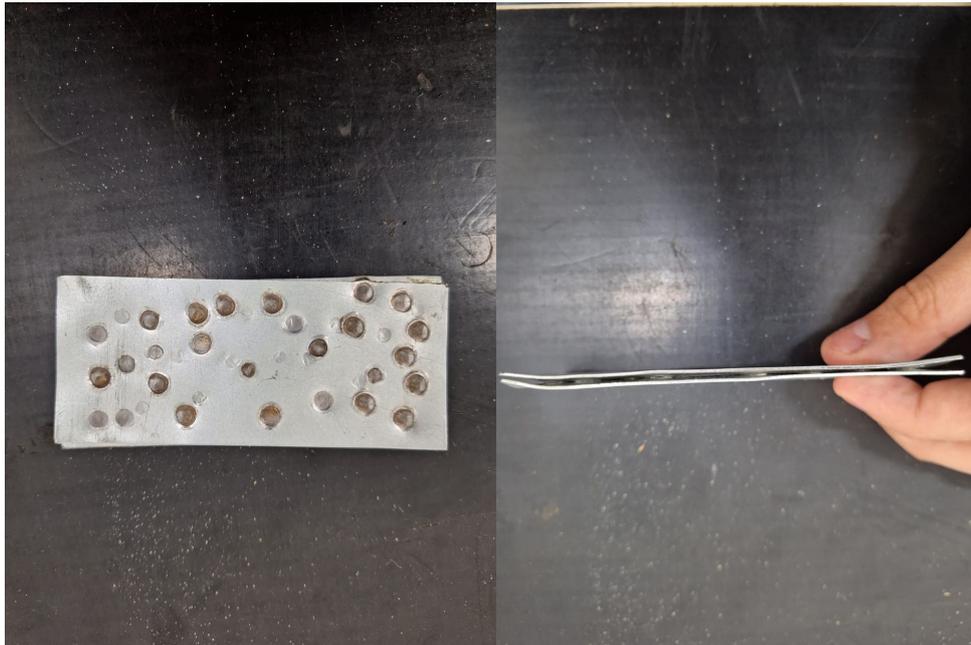
Figura 7 – Pinça de solda Obara.



Fonte: Autor (2023)

Para calibrar a pinça de solda com a tensão e corrente adequada, foi feito testes iniciais em 2 chapas de aço de 7cm x 15cm, como pode ser visto na Figura 8. É possível observar que as chapas foram efetivamente soldadas e que os pontos estavam apropriados.

Figura 8 – Chapas soldadas para teste.



Fonte: Autor (2023)

3.2 DESENVOLVIMENTO DA REDE NEURAL

O desenvolvimento da RNA foi implementada em Python com o auxílio da biblioteca TensorFlow (ABADI et al., 2015). Para rotular o banco de dados foi utilizado imagens dos pontos de solda dos corpos de prova após o peel test, onde um ponto de solda solto foi etiquetado com o número 1 e um ponto de solda não solto com o número 0. Assim, a RNA foi treinada para distinguir entre esses dois cenários, aprimorando a detecção de possíveis falhas de soldagem.

Segundo relato de integrantes da equipe de desenvolvimento, o processo de treinamento da RNA teve conjunto de dados dividido em duas partes: um conjunto de treinamento e um conjunto de teste. O conjunto de treinamento foi empregado para treinar o modelo, permitindo que a RNA aprendesse e ajustasse seus parâmetros com base nas características e labels presentes neste conjunto. O conjunto de teste, por sua vez, foi utilizado como uma forma de validação, servindo para avaliar o desempenho do modelo após o treinamento. Essa estratégia de validação é fundamental, pois permite verificar a capacidade de generalização do modelo, ou seja, sua habilidade de performar bem em dados não vistos durante o treinamento, o que é um indicativo importante da eficácia do modelo na prática.

Para enriquecer o conjunto de dados de treino e evitar o sobreajuste, foi empregado um pré processamento na RNA. Um processo de aumento de dados conhecido como augmentação de dados (data augmentation). Este processo envolveu a rotação das imagens existentes em ângulos de 90 a 180 graus, mantendo suas respectivas etiquetas (labels). Este método aumentou a quantidade de dados

disponíveis para treinamento, proporcionando à rede uma oportunidade de aprender com uma variedade maior de exemplos e, conseqüentemente, aumentando a sua capacidade de generalização.

3.2.1 Arquitetura da rede neural

A arquitetura da RNA consistiu em camadas densamente conectadas (Dense), alternadas com uma camada de regularização (Dropout) para prevenir o sobreajuste. O modelo foi compilado com a função de perda 'binary_cross_entropy', apropriada para problemas de classificação binária, e otimizada usando o algoritmo 'adam'.

A RNA foi treinada utilizando o método 'fit' do TensorFlow. Este procedimento iterativo ajustou os parâmetros do modelo para minimizar a função de perda, resultando em um modelo capaz de classificar as imagens do banco de dados. O desempenho do modelo foi avaliado em termos de sua precisão na classificação de imagens da base de dados de testes.

Figura 9 – Exemplo da arquitetura da RNA.

```

1 import tensorflow as tf
2 from tensorflow.keras.models import Sequential
3 from tensorflow.keras.layers import Dense, Dropout
4
5 # Define o modelo.
6 model = Sequential()
7 model.add(Dense(kernel = (3,3), batch_size))
8 model.add(Dense(Dense(kernel, 254))
9 model.add(Dropout(0.5))
10 model.add(Dense(2, activation='softmax'))
11
12 # Compila o modelo.
13 model.compile(loss='binary_crossentropy', optimizer='adam')
14 model.fit()

```

Fonte: Autor (2023)

A Figura 9 apresenta apenas uma seção da estrutura da RNA, destacando a ordem de como ela foi modelada. Contudo, as informações omitidas não comprometem a compreensão geral da RNA.

3.3 CONEXÃO DO CÓDIGO PYTHON COM O CLP

O CLP utilizado para os testes locais, foi o CompactLogix da Rockwell Automation. Já o teste realizado no laboratório do cliente, em São Caetano do Sul, foi utilizado um ControlLogix, da mesma fabricante, para realizar a comunicação. Este laboratório possui o mesmo sistema e configuração da planta de fábrica em São José dos Campos, no qual o projeto será implementado primeiro.

Esta integração é fundamental para a execução eficiente de sistemas de automação que empregam técnicas avançadas de inteligência artificial, como as redes neurais. Através do uso de uma versão modificada da biblioteca Pylogix, foi possível estabelecer uma comunicação eficaz entre o CLP e o Python. A seguir serão apresentados detalhes do código em Ladder e Python, demonstrando como essa integração foi realizada na prática.

3.3.1 Código Python

Para o código python foi utilizado como base a biblioteca do Pylogix (DMROEDER, 2023) para conectar com o CLP da Rockwell. Essa biblioteca possui uma classe chamada Pylogix e 3 métodos que foram utilizados no código. O método para iniciar a conexão com o CLP chamada de Connect, o método de leitura da tag chamada de Read e o método de escrita da tag chamada de Write. Para se adequar ao nosso sistema, esses métodos sofreram alteração na sua base sendo possível estabelecer a conexão com o PLC de acordo com nossa necessidade.

Para iniciar o código, foi utilizado o método Connect que possui a função de realizar a conexão entre o PLC e o servidor onde está o código. É utilizado o Internet Protocol (IP) do CLP e o IP do servidor. O arquivo foi chamado de tag_monitor e irá monitorar e enviar para o Redis, o banco de dados em memória para um armazenamento de dados em tempo real. O método Read realiza a leitura da tag para monitorar os valores das tags e o método Write é responsável pela escrita destes valores nas tags.

Foi utilizado a base da função *Adapter* encontrada no *branch* experimental do Pylogix e adaptada para o nosso sistema. Essa função permite comunicar de forma implícita de classe 1 necessário para uma comunicação mais rápida. Além disso, foi feita uma classe chamada de Log para monitor erros e retornos das funções.

A Figura 10 exibe a função de conexão do Python com o CLP pela biblioteca do Pylogix. Por conta do Pylogix ter sido alterado para se adequar ao modelo próprio, o código foi alterado para preservar as questões industriais, sendo apresentado um exemplo do que foi feito.

Já a função READ com o propósito de leitura do valor da tag, realiza a leitura das tags e envia para o banco de dados do Redis. A Figura 11 exibe a leitura e o envio para o banco de dados, em caso de falha a leitura da tag ele envia uma mensagem que não foi possível realizar a leitura e conseqüentemente não foi possível enviar para o banco.

Por fim a função WRITE é utilizada quando é necessário alterar o valor da tag.

Figura 10 – Função para conexão entre PLC e Python.

```
def CONNECT(self):
    # Creating Connection
    try:
        self.LOG_PLC.info("TRYING TO CONNECT TO PLC")
        # Open Adapter to Communicate
        self.COMMUNICATION = Adapter()
        self.COMMUNICATION.PLCIPAddress = self.PLC_IP
        self.COMMUNICATION.LocalIPAddress = os.environ.get("IP_PLC_SERVER")
        try:
            self.COMMUNICATION.Start()
        except Exception as error:
            self.LOG_PLC.error(error)
    except Exception as error:
        self.LOG_PLC.error(error)
```

Fonte: Autor (2023)

Figura 11 – Função de leitura da tag.

```
def READ(self, tag_values):
    # Get Tags to Loop
    try:
        for i, tag in enumerate(self.PLC.TAGS):
            try:
                if tag_values.Status == "Success":
                    self.WRITER_TAG.redis_insert(
                        tag, str(tag_values.Value[i]))
                else:
                    self.LOG_SERVER.error("UNSUCCESSFUL READ: {} Error:{}".format(
                        tag, tag_values.Status))
            except Exception as error:
                self.LOG_SERVER.error("CAN'T PUBLISH TAG VALUE IN SERVER {} Tag:{}".format(
                    os.environ.get('REDIS_SERVER_CAMERA'), tag))
                self.LOG_SERVER.error(error)
    except Exception as error:
        self.LOG_SERVER.error(error)
```

Fonte: Autor (2023)

As tags que utilizam esta função são *inputs* do tipo BOOL.

3.3.2 Código Ladder

A programação consiste em seis tags de software principais para o controle de produção, sendo uma de entrada e cinco de saída. As tags em questão são Style, PVI, Schedule, AcquireImage, AcquireImageStatus e MaincycleProcComp.

3.3.3 Tags

A tag Style é responsável pela identificação do estilo de peça em processamento, que pode ser de dois tipos diferentes e se alternam a cada ciclo.

Figura 12 – Função de escrita da tag.

```
def WRITE(self, tag_index, value):  
    try:  
        self.COMMUNICATION.InputData[tag_index] = value  
    except Exception as error:  
        self.LOG_PLC.error(error)  
    return False
```

Fonte: Autor (2023)

Já a tag PVI é responsável por armazenar o número de identificação da peça, que é incrementado a cada ciclo.

A tag Schedule controla a quantidade de pontos de solda já realizado a cada ciclo, finalizando com 20 pontos de solda total para cada peça. A tag AcquireImage é uma tag de controle que indica se o robô está na posição correta para capturar a imagem da peça. Quando esta tag é verdadeira, o robô está pronto para capturar a imagem.

A tag AcquireImageStatus é uma tag de saída que envia um sinal para o cabeçote da câmera, indicando que o robô está pronto para capturar a imagem da peça. No entanto, essa tag só pode enviar um sinal se a tag AcquireImage estiver verdadeira, garantindo que o robô esteja na posição correta para a captura da imagem.

Por fim, a tag MaincycleProcComp é uma tag de verificação do final do ciclo, que indica que o ciclo de processamento da peça está completo e o robô pode passar para a próxima peça.

A forma para manipular e ler as tags é implementada em Python utilizando a biblioteca do pylogix própria para os CLPs da Rockwell. A conexão é feita com um método da classe da biblioteca e são utilizados os métodos de leitura e escrita própria da biblioteca. O código monitora as tags a cada 500 ms e envia para o banco de dados.

A Tabela 3 mostram a lista de tags utilizadas para a leitura e escrita. A leitura é caracterizada como uma tag de saída, enquanto a escrita é caracterizada como tag de entrada. Na lista, o I/O representa o Input e Output, sendo I como input e O como Output.

3.3.4 Lógica do programa

O programa apresentado no trabalho são trechos de código com informações sensíveis omitidas. Para o nosso teste de local, o programa foi focado apenas na inspeção de solda e para a representação da soldagem, um temporizador foi adicionado

Tabela 3 – Lista de Tags.

Tags	I/O	Tipo
Style	Saída	DINT
PVI	Saída	DINT
Schedule	Saída	DINT
AcquireImage	Saída	BOOL
AcquireImageStatus	Entrada	BOOL
MaincycleProcComp	Saída	BOOL

Fonte: Autor (2023)

para que o tempo da simulação fosse o mais próximo possível do sistema real. A Figura 13 mostra o início do programa com um contato normalmente fechado para o funcionamento de um loop do programa e o temporizador de simulação de solda.

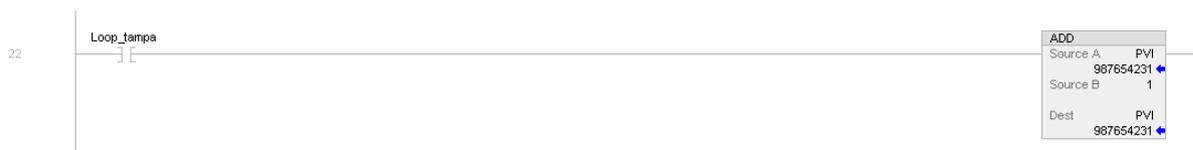
Figura 13 – Início do programa Ladder.



Fonte: Autor (2023)

O PVI é incrementado pela função matemática "ADD" no ladder. Ele é composta por um número de 9 dígitos e a cada ciclo ele adiciona 1 unidade no número. A Figura 14 ilustra um contato normalmente aberto que é acionado a cada ciclo, repetindo o loop e a função "ADD" mencionada anteriormente.

Figura 14 – Lógica do PVI.

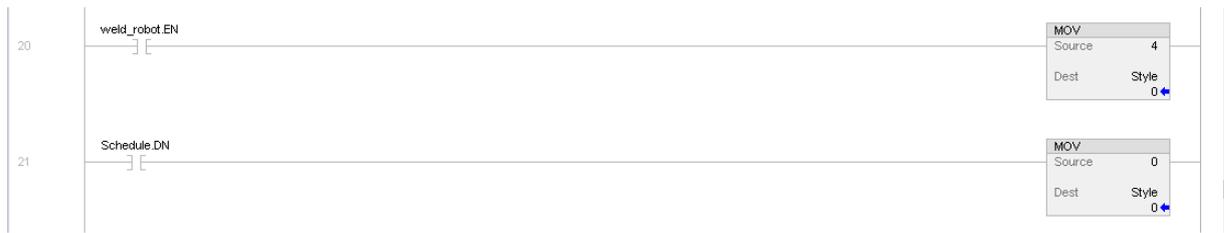


Fonte: Autor (2023)

O Style representa o estilo da peça que será soldada. Para isso é utilizado um número inteiro que representa cada tipo de peça. Nos testes locais, como são baseados apenas nas chapas traseiras da carroceria, o Style alterna apenas entre 2 números, 0 para quando o robô ainda não está manipulando a peça e 4 que é um dos estilos de peça catalogada da cliente. A Figura 15 exibe a função "MOV" em que é possível mover o valor de uma tag ou um número para uma outra tag.

Quando o robô chega na posição para tirar a foto, a tag AcquireImage é acionada e se mantém True enquanto AcquireImageStatus não for acionado. Dessa forma é possível evitar que a câmera tire foto quando o robô ainda não chegou na posição correta ou que o robô vá para a próxima posição antes de ter tirado a foto. A Figura 16 mostra AcquireImage e AcquireImageStatus em conjunto e quando ambos

Figura 15 – Lógica do Style.



Fonte: Autor (2023)

forem True a foto é tirada.

Figura 16 – Lógica do AcquireImage e AcquireImageStatus.



Fonte: Autor (2023)

Já o Schedule é um contador para cada vez que a foto é tirada totalizando, neste teste, 20 pontos de solda. Quando o robô termina a inspeção, o contador é resetado para a próxima peça. A Figura 17 apresenta o contador Schedule e o momento em que é resetada.

Figura 17 – Lógica do Schedule.



Fonte: Autor (2023)

Finalmente, MainCycleProcComp é uma tag BOOL que recebe True quando o ciclo termina mantendo até o robô manipular a próxima peça. A Figura 18 retrata a tag sendo ativada após o término de inspeção.

Figura 18 – Lógica do MainCycleProcComp.



Fonte: Autor (2023)

3.3.5 Troca de serviço de comunicação do protocolo Ethernet/IP

A terminologia "Classe 1" e "Classe 3" é comumente usada na comunicação em rede industrial, especialmente no contexto do protocolo Ethernet/IP, amplamente aplicado em sistemas CLP (Controlador Lógico Programável). Estas classes representam diferentes formas de serviços de comunicação, cada uma adequada para diferentes tipos de operações, e são definidas pelo protocolo Ethernet/IP (Precision Electronic Services, 2014).

A Classe 1 refere-se à comunicação implícita de Entrada/Saída (I/O) em tempo real do Ethernet/IP (Precision Electronic Services, 2014). Esta classe é orientada à conexão e utiliza o protocolo CIP (Common Industrial Protocol) para garantir uma transferência de dados de tempo real entre dispositivos de origem e destino. Esta forma de comunicação é ideal para o controle de dispositivos onde a sincronização de tempo é fundamental, proporcionando uma resposta rápida e precisa às mudanças nas condições do sistema (Automation Direct, 2023).

Por outro lado, a Classe 3 é um serviço de mensagens explícitas que também utiliza conexões CIP orientadas à conexão. Este tipo de comunicação é geralmente usado para operações como programação, configuração e coleta de dados, onde o tempo não é um fator tão crítico. A Classe 3 permite uma comunicação mais complexa, incluindo mensagens de solicitação e resposta. Embora ambos os serviços de comunicação sejam confiáveis, eles diferem na maneira como lidam com a temporização e a complexidade dos dados transmitidos (Automation Direct, 2023).

Inicialmente o projeto utilizava a Classe 3 como o serviço de comunicação para ler e escrever nas tags do programa porém foi necessário a troca para a Classe 1 para que a comunicação fosse a mais rápida possível. Com a classe 3, pequenos atrasos ocorriam na troca de informações dos valores das tags deixando menos eficiente e funcional para cliente. A classe 1, por ser em tempo real, resolveu esse problema.

3.4 TESTE LOCAL DE CONEXÃO E DO SISTEMA INTEGRADO

Em 19 de abril de 2023, foi realizado uma visita ao laboratório de testes do cliente, com o intuito de implementar a comunicação Ethernet/IP Classe 1 entre o código Python e o CLP ControlLogix, propriedade do cliente. O teste resultou em êxito na comunicação, fato considerado positivo uma vez que, anteriormente, a verificação havia sido realizada apenas no CompactLogix. Portanto, o código Python demonstrou versatilidade, assegurando um desempenho qualitativo, possibilitando a modificação dos controladores sem interferência na comunicação estabelecida entre eles.

4 RESULTADOS

Nesta seção, apresentaremos e discutiremos os resultados obtidos a partir dos métodos implementados em nosso estudo. O foco principal será na análise do desempenho da rede neural artificial(RNA) desenvolvida e na eficácia da conexão estabelecida entre o Controlador Lógico Programável (CLP) e o código em Python.

4.1 FÁBRICA DA CLIENTE

A linha de montagem apresentada é baseada na soldagem das chapas traseiras da carroceria realizada na fábrica da cliente localizada em São José dos Campos. No momento, a linha de produção utiliza a inspeção humana para análise de pontos de solda. Após a implementação definitiva do projeto, a estrutura será alterada para que braço robótico manipule a chapa de forma que a camera capture os pontos para uma análise de máquina.

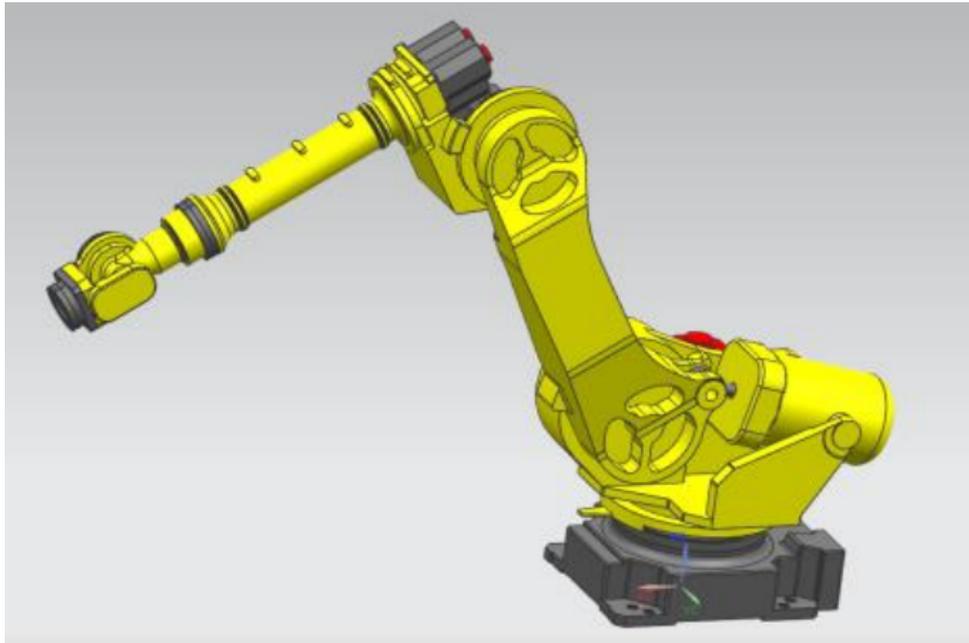
4.1.1 Funcionamento da linha de produção

A linha de produção das chapas traseiras da carroceria utiliza um robô do modelo Fanuc R-2000iB / 210F. Esse equipamento manipula de chapa em chapa que estão empilhadas em um monte, levando-as para uma pinça de solda, onde são realizados 20 pontos de solda. O processo de soldagem tem duração de cerca de 45 segundos. Ao finalizar a soldagem, o robô transporta a peça para um trilho por onde passará por uma análise de solda visual. A Figura 19 apresenta o modelo do robô na fábrica da cliente.

Para melhor compreensão do funcionamento, a Figura 20 ilustra um diagrama de atividades da linha de produção. Após a conclusão do projeto, o robô deverá ser capaz de manipular a chapa para realizar a solda e depois levar até o cabeçote da câmera para que seja possível fotografar todos os pontos recém soldados. As imagens são enviadas passadas pela RNA, que analisa cada ponto e verifica sua qualidade. Todas as informações são exibidas em uma Interface Homem-Máquina(IHM) por meio do aplicativo desenvolvido pela empresa, permitindo a monitoração da peça. O robô, então, coloca a peça no trilho, e o ciclo é completado.

Caso a confiança da RNA fique abaixo de 80%, é necessário que seja realizado um novo treinamento para garantir a correta classificação dos pontos de solda. Quando um ponto é classificado como inadequado, ele é inspecionado manualmente por um

Figura 19 – Robô Fanuc R-2000iB.



Fonte: Adaptado de HERBÚS; OCIEPKA (2016)

operário. Se necessário, o ponto é corrigido e a peça é novamente posicionada no trilho. A Figura 21 exibe o futuro processo de produção com visão de máquina.

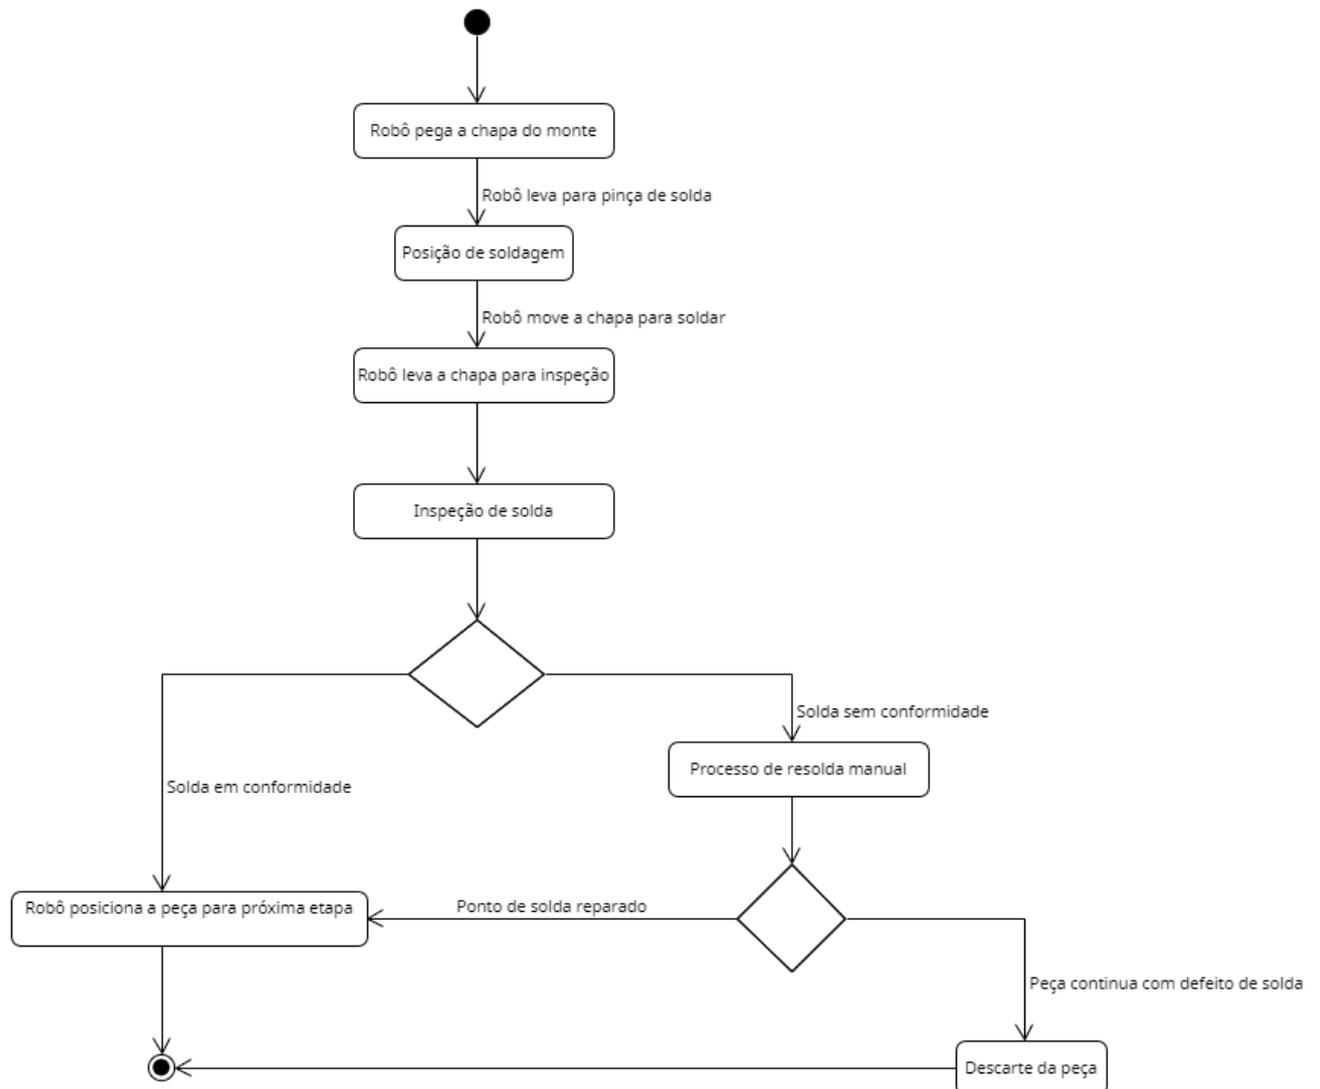
Ao final do processo, todas as peças são inspecionadas e as que atendem aos padrões de qualidade são aprovadas e enviadas para a próxima etapa da linha de produção. Esse processo garante que as peças soldadas sejam de alta qualidade e que os problemas sejam identificados e corrigidos rapidamente para manter a eficiência e a produtividade da linha de produção.

A Figura 22 mostra um diagrama de integração entre o Python, CLP e o Robô. Dessa forma, é possível visualizar que o código Python presente na CPU, comunica com o CLP por meio do protocolo Ethernet/IP e em seguida comunica-se com o Robô. O robô também se comunica com o CLP para alterar as tags e por fim o CLP volta a se comunicar com a CPU.

4.2 MÉTRICAS DE QUALIDADE DA REDE NEURAL

Durante o treinamento da rede foi usado uma base de dados que foram divididos em 2, uma base de treino e uma base de teste. A base de treino é utilizada para o desenvolvimento e treinamento do modelo, enquanto a base de teste é utilizada para avaliar o desempenho do modelo em dados nunca antes vistos. Durante o treinamento, o modelo utiliza somente a base de treino para aprender a relação entre as variáveis e

Figura 20 – Diagrama de atividades da linha de produção.



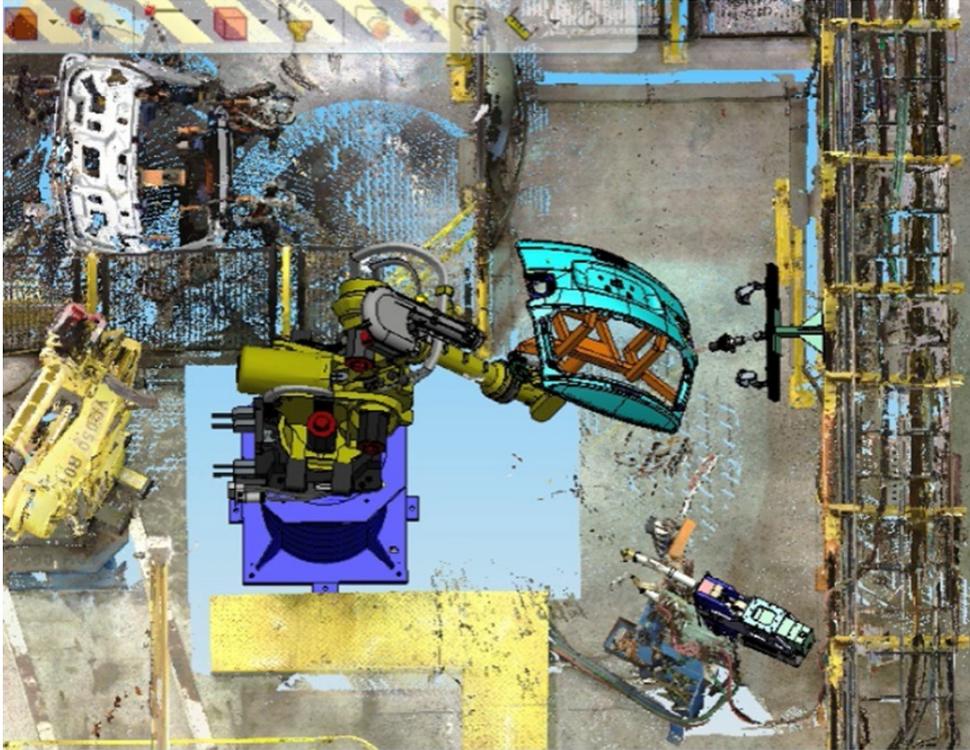
Fonte: Autor (2023)

não tem acesso à base de teste. Ao final do treinamento, o modelo é avaliado na base de teste, que contém tanto as entradas quanto as saídas esperadas. O resultado da previsão do modelo é comparado com a saída esperada para medir a sua precisão e performance.

4.2.1 Treinamento da rede

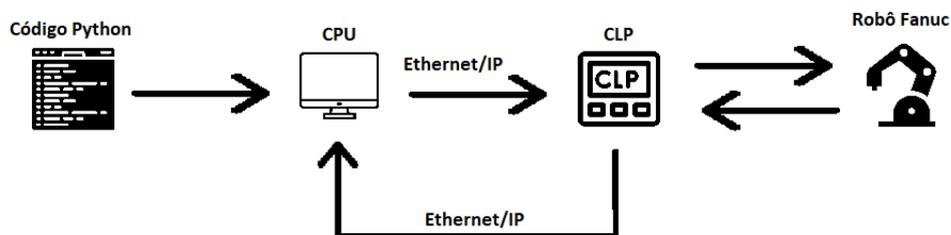
Para o treinamento da rede foi dado como entrada informações como o tipo de eletrodo, frequência, valor de corrente e tensão da pinça de solda. Dessa forma foi utilizado o cobre berílio com capa de 6mm de diâmetro, uma frequência de 50hz, faixa entre 0-100kA amperes e 0-2 Volts. O material utilizado para a soldagem foi o AKDQ CR4, que é um material para estampagem de 0.7mm de espessura. A saída esperada

Figura 21 – Processo de produção.



Fonte: Autor (2023)

Figura 22 – Diagrama do fluxo de integração Python/CLP.



Fonte: Autor (2023)

da rede neural é a rotulação do banco de dados em comparação ao resultado do peel test.

A geração de amostras é um processo caro e trabalhoso e para reduzir os custos do treinamento, foi realizada uma técnica chamada de *Data Augmentation*. Esta técnica permite aumentar o número de amostras sem a necessidade de adquirir mais dados com uma transformação de imagem para criar variações artificiais dos dados de entrada.

A técnica realizada foi a rotação da imagem em 90 ou 180 graus, que pode ser aplicada várias vezes com uma label idêntica. Além disso, a alteração da cor da imagem é outra técnica que pode ser usada para gerar mais variações.

No entanto, é importante considerar o impacto dessas técnicas de data

augmentation na classificação dos dados. Por exemplo, a cor amarela pode ser uma característica de pontos bons na imagem, e ao alterar a cor da imagem, pode-se perder essa informação importante. Portanto, é necessário avaliar cuidadosamente o impacto dessas técnicas na precisão da classificação e adaptá-las de acordo com o tipo de dados e o objetivo da classificação.

4.3 RESULTADO DA REDE NEURAL

O modelo de classificação desenvolvido foi avaliado com base nas métricas antes mencionadas, sendo a acurácia, precisão e matriz de confusão as principais delas. De acordo com os testes realizados na cliente, a acurácia geral é de 85%.

De acordo com os resultados obtidos, a diferença entre a acurácia do modelo nos dados de treinamento e nos dados de teste foi de apenas 0,77%. Isso indica que o modelo apresentou uma capacidade satisfatória de generalização, uma vez que a discrepância entre o desempenho nos dados de treino e teste foi mínima.

4.3.1 Matriz de confusão

A precisão do modelo foi avaliada para cada uma das classes de interesse: *Interfacial* e *Pullout*. A precisão obtida para a classe *Interfacial* foi de 87,5% e para a classe *Pullout* foi de 84,4%. Esses resultados indicam que o modelo é bastante eficaz em prever corretamente ambas as classes. A Tabela 4 apresenta a matriz de confusão do modelo:

Tabela 4 – Resultado matriz de confusão.

	Negativo	Positivo
Negativo	135	5
Positivo	25	35

Fonte: Autor (2023)

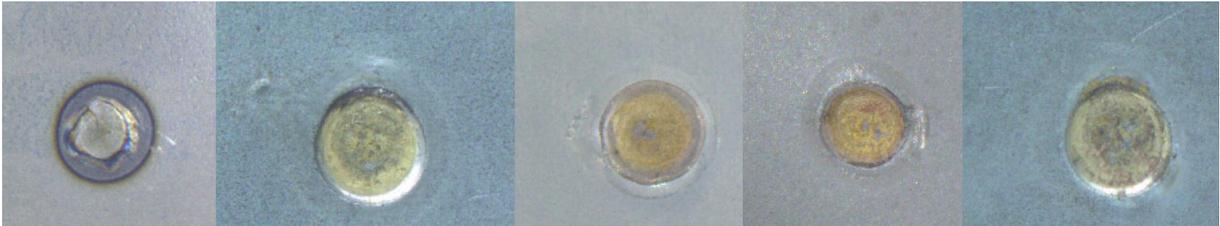
Nota-se na Tabela 1 que o modelo obteve 35 verdadeiros positivos (VP) e 135 verdadeiros negativos (VN), indicando as situações em que fez previsões corretas para as classes *Interfacial* e *Pullout*, respectivamente. Além disso, o modelo apresentou 25 falsos positivos (FP) e 5 falsos negativos (FN), representando as ocasiões em que errou as previsões para as respectivas classes.

Dessa forma, considerando os resultados apresentados, pode-se concluir que o modelo de classificação desenvolvido apresentou um desempenho satisfatório, com alta acurácia e precisão e uma taxa mínima de erros.

4.3.2 Qualidade da solda

Os pontos de solda em conformidade por solda a ponto por resistência são caracterizados por diâmetros uniformes e adequados, que garantem a aderência e resistência mecânica da junta. Eles apresentam uma aparência suave e arredondada, sem asperezas ou irregularidades. Na Figura 23 é um exemplo de pontos bons de solda capaz de suportar a carga necessária para a aplicação em questão.

Figura 23 – Exemplos de pontos de solda em conformidade.



Fonte: Autor (2023)

Por outro lado, os pontos de solda sem conformidade podem ser causados por diversos fatores, como a configuração inadequada do equipamento de solda, a falta de limpeza e preparação adequada da superfície das peças, a pressão e a duração inadequadas da aplicação dos eletrodos e o uso de materiais de soldagem de baixa qualidade. Pontos de solda ruins apresentam diâmetros inconsistentes, falta de aderência, porosidade, trincas ou outras falhas na aparência e na aderência da junta. A Figura 24 demonstra uns exemplos de pontos com defeito de solda.

Figura 24 – Exemplos de pontos de solda sem conformidade.



Fonte: Autor (2023)

A Figura 25 mostra exemplos de pontos de solda erroneamente classificados como corretos pela RNA, representando falsos negativos de qualidade de solda. Esses erros podem ocorrer devido à semelhança desses pontos com soldas genuinamente bem executadas, apresentando uma forma arredondada e aparentemente correta.

Por fim, a Figura 26 ilustra os casos em que ocorrem falsos positivos nos pontos de solda, ou seja, a RNA os classifica como defeituosos, apesar de possuírem a qualidade requerida. Essa classificação equivocada pode ser atribuída a questões de iluminação e à aparência sutil da solda.

Figura 25 – Exemplos de pontos de solda falsos negativos.



Fonte: Autor (2023)

Figura 26 – Exemplos de pontos de solda falsos positivos.



Fonte: Autor (2023)

5 CONCLUSÕES

Este estudo apresentou uma abordagem para a análise de solda, utilizando visão computacional e redes neurais artificiais. Através da exploração dos parâmetros da soldagem por resistência e da discussão dos métodos de análise de solda existentes, foi possível desenvolver um sistema que integra essas tecnologias. Este sistema demonstrou ser uma ferramenta eficaz, alcançando uma acurácia de 85% na análise de solda, com apenas 0,77% de diferença entre os dados de treinamento e o dados de teste.

Além disso, o trabalho abordou a integração do código Python com o Controlador Lógico Programável (CLP) usando o protocolo Ethernet/IP. Esta integração mostrou-se viável e eficaz, permitindo uma comunicação eficiente entre o sistema de análise de solda e o equipamento de soldagem. Esta abordagem abre novas possibilidades para a automação e controle de qualidade na indústria de soldagem.

Os resultados obtidos neste estudo são promissores. A aplicação de visão computacional e redes neurais na análise de solda pode superar significativamente as limitações dos métodos convencionais. Isso não apenas melhora a precisão da análise de solda, mas também aumenta a eficiência do processo de soldagem, reduzindo o tempo e o esforço necessários para a inspeção de qualidade. É importante ressaltar que a RNA foi treinada com um volume imagens considerado baixo, podendo alcançar níveis mais altos de acurácia quando treinadas com maior quantidade.

Por fim, conclui-se que este trabalho destaca a relevância e o potencial das tecnologias de visão computacional e redes neurais artificiais na melhoria da análise de solda, com uma acurácia superior a humana. Espera-se que este estudo sirva como base para futuras pesquisas e aplicações nesta área.

REFERÊNCIAS

- ABADI, M. et al. **TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems**. 2015. Software available from tensorflow.org. Disponível em: <https://www.tensorflow.org/>.
- Alusolda. A revolução da solda: Como a solda robotizada está mudando a indústria. 2023. Disponível em: <https://alusolda.com.br/a-revolucao-da-solda-como-a-solda-robotizada-esta-mudando-a-industria/>.
- Automation Direct. **EtherNet/IP for Productivity Series**. 2023. [Acessado em: 22, junho, 2023]. Disponível em: <https://www.automationdirect.com/microsites/productivity/software/help/Content/259.htm>.
- BATISTA, M. **Estudo comparativo da soldabilidade de chapas para indústria automotiva utilizando dois equipamentos de soldagem a ponto por resistência**. 2011. Dissertação (Mestrado em Engenharia Metalúrgica e de Materiais) — Escola politécnica, Universidade de São Paulo, São Paulo, 2011.
- BERTONI, A. L.; FEDER, D. V. d. S. **Rede neural convolucional aplicada à visão computacional para detecção de incêndio**. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2018.
- BERTONI, A. L.; FEDER, D. V. D. S. **Rede neural convolucional aplicada à visão computacional para detecção de incêndio**. 2018. Trabalho de Conclusão de Curso (Graduação em Engenharia Eletrônica) — Universidade Tecnológica Federal do Paraná, Curitiba, 2018.
- COELHO, F. G. F. et al. Uso de sistema de visão de baixo custo para monitoramento de distorções durante deposições multicamadas no processo de soldagem gmaw. **Soldagem & Inspeção**, SciELO Brasil, v. 25, n. 2, p. 2–10, 2020.
- COUTO, R. T. Ethernet industrial. **Monografia (Graduação em Engenharia de**, 2010.
- DEVARASIDDAPPA, D. Automotive applications of welding technology-a study. **Int. J. Modern Eng. Res**, v. 4, n. 9, p. 13–19, 2014.
- DMROEDER. **Pylogix**. 2023. <https://github.com/dmroeder/pylogix>. Accessed: 2023-06-19.
- ENAMI, M.; FARAHANI, M.; SOHRABIAN, M. Evaluation of mechanical properties of resistance spot welding and friction stir spot welding on aluminium alloys. In: **Int Conf res Sci Eng, Istanbul. Anais[...]** Turkey. Istanbul: [s.n.], 2016.
- JURASZEK, G. D. et al. Reconhecimento de produtos por imagem utilizando palavras visuais e redes neurais convolucionais. Universidade do Estado de Santa Catarina, 2014.
- LECUN, Y.; KAVUKCUOGLU, K.; FARABET, C. Convolutional networks and applications in vision. In: **Proceedings of 2010 IEEE International Symposium on Circuits and Systems (ISCAS)**. [S.l.: s.n.], 2010. p. 253–256.

- MARQUES, P. V. **Soldagem-fundamentos e tecnologia**. Belo Horizonte: Editora da UFMG, 2005.
- MARTINS, A. P.; JUNIOR, J. E. C. P. Inspeção de solda utilizando visao computacional. **Anais do 10o Simpósio Brasileiro de Automação Inteligente–X SBAI, Sao Joao Del Rey, Minas gerais**, p. 444–449, 2011.
- MATOS, P. F. et al. Relatório técnico “métricas de avaliação”. **Universidade Federal de Sao Carlos**, 2009.
- MATSUNAGA, V. Y. Curso de redes neurais utilizando o matlab. **Belém do Pará**, 2012.
- MILANO, D. de; HONORATO, L. B. Visao computacional. **Faculdade de Tecnologia, Universidade Estadual de Campinas**, 2010.
- MODENESI, P. J. Soldagem i descontinuidades e inspeção em juntas soldas. **Belo Horizonte**, 2001.
- MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. **Sistemas inteligentes-Fundamentos e aplicações**, v. 1, n. 1, p. 32, 2003.
- MUSIOL, M. Speeding up deep learning computational aspects of machine learning. n. 1, 2016.
- NA, J.-K. Phased array testing of resistance spot welds. v. 91, p. 36–39, 09 2012.
- OLIVEIRA, D. N.; BRAGA, A. P.; ALMEIDA, O. M. Fuzzy implementado em ladder com funções de pertinência descontínuas. In: **XVIII Congresso Brasileiro de Automática, Bonito**. [S.l.: s.n.], 2010. p. 12–16.
- OLIVEIRA, E. et al. Convertendo diagramas ladder em modelos de redes de petri coloridas. In: **Simpósio Brasileiro de Automação Inteligente**. [S.l.: s.n.], 2011.
- Precision Electronic Services. **Ethernet/IP Common Terminology Defined**. 2014. Disponível em: <https://www.precision-elec.com/wp-content/uploads/2014/08/ethernet-ip-common-terminology-defined.pdf>.
- RAJALAKSHMI, A. S.; SHAFIQ, T. Modeling of spot weld with failure for crash simulations. Chalmers University of Technology Gothenburg, Sweden, 2017.
- RAMOS, J. L. C. et al. Um estudo comparativo de classificadores na previsão da evasão de alunos em ead. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2018. v. 29, n. 1, p. 1463.
- RAUBER, T. W. Redes neurais artificiais. **Universidade Federal do Espírito Santo**, v. 29, 2005.
- RIBEIRO, A. L. A. et al. Inspeção de qualidade de solda por visão computacional. 2022.
- MONTE SENA, F. **Metodologia de inspeção para processo de soldagem por resistência a ponto via visão de máquina**. 2019. Dissertação (Mestrado em Materiais, Manufatura e Automação) — Instituto Tecnológico de Aeronáutica, São José dos Campos, 2019.

SILVA, R. Z. da et al. Análise inteligente de modos de transferência metálica em soldagem gmaw a partir de visao computacional. **Anais do XIII Simpósio Brasileiro de Automação Inteligente**, p. 5650–5655, 2017.

SUMMERVILLE, C.; COMPSTON, P.; DOOLAN, M. A comparison of resistance spot weld quality assessment techniques. **Procedia Manufacturing**, Elsevier, v. 29, p. 305–312, 2019.

WEIS, A. A. **Sistema de visão computacional para soldagem linear automatizada de chapas chanfradas**. Dissertação (Mestrado), 2018.

WILLIAMS, N.; PARKER, J. Review of resistance spot welding of steel sheets part 1 modelling and control of weld nugget formation. **International materials reviews**, v. 49, n. 2, p. 45–75, 2004.

ZHANG, H.; SENKARA, J. **Resistance welding: fundamentals and applications**. [S.l.]: CRC press, 2011.