



**REVISTA BRASILEIRA DE MECATRÔNICA**  
FACULDADE SENAI DE TECNOLOGIA MECATRÔNICA

**INTEGRAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA INDÚSTRIA 4.0 UTILIZANDO FERRAMENTAS  
LOW-CODE PARA VISÃO COMPUTACIONAL**

**INTEGRATION OF ARTIFICIAL INTELLIGENCE IN INDUSTRY 4.0 USING LOW-CODE TOOLS FOR  
COMPUTER VISION**

Dhyonatan Santos de Freitas<sup>1, i</sup>  
Miguel Bozer da Silva<sup>2, ii</sup>  
Jose Roberto Dos Santos<sup>3, iii</sup>  
Ricardo Martinez Vicentini<sup>4, iv</sup>

Data de submissão: (21/11/2024) Data de aprovação: (26/03/2025).

**RESUMO**

A Indústria 4.0 marca uma mudança significativa no panorama industrial, caracterizada pela integração entre tecnologias da informação e automação industrial, visando aprimorar a agilidade na tomada de decisões. Nesse contexto, a Inteligência Artificial (IA) desempenha um papel fundamental, possibilitando análises avançadas e otimização de recursos, resultando em previsões precisas e decisões mais ágeis. No entanto, a implementação eficaz da IA enfrenta desafios, especialmente em relação à complexidade algorítmica e à integração com sistemas de automação industrial existentes. Este trabalho propõe uma abordagem baseada na implementação de um sistema de visão computacional, utilizando duas ferramentas low-code. Essa aplicação tem como objetivo realizar inspeções de qualidade na montagem de peças em uma planta educacional de manufatura avançada. Os resultados obtidos por meio dessa abordagem demonstram uma solução que simplifica tanto a implantação quanto a operação de sistemas de IA na automação industrial.

**Palavras-chave:** Indústria 4.0; inteligência artificial; Node-Red; *teachable machine*; *low-code*.

**ABSTRACT**

Industry 4.0 marks a significant change in the industrial panorama, characterized by the integration between information technologies and industrial automation, aiming to enhance decision-making agility. In this context, Artificial Intelligence (AI) plays a fundamental role, enabling advanced analysis and resource optimization, resulting in accurate predictions and faster decisions. However, effective implementation of AI poses several challenges,

<sup>1</sup> Pós-graduando na Faculdade SENAI de Tecnologia Mecatrônica. E-mail: dhyonatan.freitas@edu.sc.senai.br

<sup>2</sup> Docente na Faculdade SENAI de Tecnologia Mecatrônica. E-mail: miguel.bozer@sp.senai.br

<sup>3</sup> Docente na Faculdade SENAI de Tecnologia Mecatrônica. E-mail: [joseroberto@sp.senai.br](mailto:joseroberto@sp.senai.br)

<sup>4</sup> Docente na Faculdade SENAI de Tecnologia Mecatrônica. E-mail: ricardo.vicentini@sp.senai.br

particularly in terms of algorithmic complexity and system integration. This work proposes implementing a computer vision system using two low-code tools. This application aims to perform quality inspections in the assembly of parts in an educational advanced manufacturing plant. The results obtained through this approach demonstrate that this approach simplifies both the implementation and operation of AI in industrial automation.

**Keywords:** Industry 4.0; artificial intelligence; Node-Red; teachable machine; low-code.

## 1 INTRODUÇÃO

O conceito de Indústria 4.0, surgido em 2011, não se limita apenas à digitalização e automação dos processos produtivos, mas abrange também a integração de tecnologias da informação e automação industrial, visando à redução da latência na tomada de decisões gerenciais e facilitando o acesso a dados confiáveis da operação industrial para maximizar o valor do negócio (Becker *et al.*, 2017). Segundo Hackathorn (2002), quanto menor o tempo de resposta a um evento, mais eficiente será a resposta, evidenciando a importância da agilidade e adaptabilidade dos processos industriais modernos. Neste contexto, organizações com um alto nível de maturidade na Indústria 4.0 demonstram uma maior rapidez na resposta a eventos, o que se torna crucial para a eficiência operacional, ressaltando a importância da agilidade e adaptabilidade das organizações diante de adversidades inesperadas (Becker *et al.*, 2017). Conforme destacado por Hackathorn (2002), o fenômeno da latência na tomada de decisão refere-se ao intervalo de tempo entre a ocorrência de um evento e a decisão que dele decorre. Esse atraso pode ser causado pelas etapas intermediárias, como armazenamento e processamento de dados, além da própria decisão em si. Organizações que possuem um alto nível de maturidade em seus processos industriais tendem a empregar estratégias e tecnologias que minimizem esse atraso, permitindo respostas mais rápidas e ações imediatas aos eventos.

A metodologia proposta pela Academia Alemã de Ciências e Engenharia (Acatech) permite às empresas avaliarem sua maturidade em relação à indústria 4.0 e desenvolverem estratégias para aumentá-la, visando maximizar os benefícios econômicos da transformação digital (Becker *et al.*, 2017). Esse índice de maturidade auxilia as organizações a compreenderem seu progresso na transformação digital e planejarem suas próximas etapas. A Acatech descreve seis níveis: a) computarização; b) conectividade; c) visibilidade; d) transparência; e) capacidade de previsão; e f) adaptabilidade. Começando com a automação básica no nível de computação, as organizações avançam para a integração de sistemas no nível de conectividade, seguido pela capacidade de monitorar operações em tempo real no nível de visibilidade. A transparência é alcançada por meio da compreensão detalhada do estado da planta, enquanto a capacidade de previsão permite prever tendências futuras. O ápice da maturidade é atingido no nível de adaptabilidade, onde as organizações podem ajustar rapidamente suas operações e estratégias conforme as mudanças no ambiente de negócios ou problemas inesperados, contudo, tem se demonstrado uma tarefa desafiadora (Becker *et al.*, 2017).

A análise do índice proposto pela Acatech é crucial para que as organizações compreendam os diferentes níveis de maturidade na transformação digital e possam estabelecer metas e estratégias adaptadas a cada área, visando garantir a sustentabilidade e a saúde financeira do negócio. Em relação à adaptabilidade e otimização dos processos, a

adoção de Inteligência Artificial (IA) se destaca como uma tecnologia habilitadora promissora. Williamson & Vijayakumar (2021), apresenta a Inteligência Artificial (IA) como uma tecnologia habilitadora essencial na indústria 4.0, principalmente em aplicações voltadas para a visão computacional. Essa abordagem visa, entre outros aspectos, aprimorar a captura e avaliação de dados em tempo real, permitindo uma resposta mais ágil e precisa às demandas operacionais. O desenvolvimento de modelos de IA para a classificação de objetos em ambientes industriais, pode ser parametrizado de forma a otimizar tanto a eficiência quanto a agilidade no processo de treinamento. Além disso, métricas de desempenho, como a acurácia e a perda, desempenham um papel crucial na avaliação da eficácia dos modelos de IA. A acurácia reflete a capacidade do modelo de classificar corretamente as amostras, enquanto a perda mede a divergência entre as previsões do modelo e os rótulos reais durante o treinamento. Ao final do treinamento, a matriz de confusão é gerada como uma ferramenta fundamental para a visualização da precisão e dos erros do modelo, facilitando a compreensão do seu comportamento em relação aos dados de teste. Esses conceitos são essenciais na implementação de IA em sistemas de visão computacional, fornecendo transparência e eficiência ao processo de tomada de decisão, e são alinhados aos princípios da Indústria 4.0, que busca a integração inteligente entre sistemas e a automação avançada para alcançar novos patamares de produtividade e adaptabilidade industrial.

De acordo com Weichert *et al.* (2019), a IA oferece vantagens significativas, como economia de tempo, energia e recursos, além da redução de desperdícios através da automatização do tratamento e análise de dados, podendo inferir ações futuras e realizar controles de qualidade menos invasivos. No entanto, a implementação da IA enfrenta desafios, como a complexidade dos algoritmos, a integração com sistemas legados existentes e as limitações das arquiteturas monolíticas de software (Peres et al., 2020; Williamson & Vijayakumar, 2021; Lucio, 2017), além de serem considerados não determinísticos ou "caixas pretas". Tais desafios evidenciam a necessidade de capacitação das equipes para lidar com as novas tecnologias, principalmente devido à convergência entre Tecnologia da Informação (TI) e Tecnologia da Automação (TA). Como alternativa para superar esses desafios, sugere-se a utilização de ferramentas que possam abstrair a complexidade da implementação da IA, bem como sua integração com o ecossistema da automação industrial, permitindo que ambas funcionem de maneira colaborativa.

Nesse contexto, a adoção de ferramentas ou tecnologias *low-code* torna-se uma alternativa promissora, uma vez que elas oferecem uma abordagem simplificada para o desenvolvimento de sistemas de IA na automação industrial, em contraste com o tradicional desenvolvimento via *hard code*. Essas ferramentas permitem aos usuários construir modelos de IA sem a necessidade de profundo conhecimento em programação, agilizando o processo de desenvolvimento com o uso de interfaces visuais e componentes pré-configurados. Além disso, oferecem recursos de integração que facilitam a conexão com sistemas legados e a interoperabilidade com outras tecnologias, mitigando os desafios associados à integração da IA com o ecossistema existente de automação industrial (MIT Technology, 2022). Ao abstrair a complexidade da implementação da IA, as ferramentas *low code* permitem que as organizações alcancem uma maior adaptabilidade e otimização dos processos, essenciais para a transformação digital na indústria 4.0. Elas capacitam as equipes a lidar com as novas tecnologias de forma mais eficaz, promovendo uma colaboração harmoniosa entre a TI e a TA e impulsionando a inovação em toda a cadeia de valor.

O objetivo geral deste trabalho é realizar a implementação de um sistema de visão computacional com controle por Inteligência Artificial (IA), adotando ferramentas *low-code* para o seu desenvolvimento e integração com a automação industrial. Essa iniciativa visa não apenas promover transparência e eficiência em todos os processos, mas também facilitar a adoção das tecnologias essenciais para uma transição plena rumo à Indústria 4.0.

O restante deste trabalho está organizado da seguinte forma: na Seção 2 é apresentado o estado da arte em termos da implementação de IA em sistemas de automação utilizando ferramentas *low-code* para o seu desenvolvimento e integração. Em seguida, a Seção 3 apresenta a metodologia proposta para a implementação e integração da IA em uma planta de manufatura educacional. A seguir a Seção 4 apresenta os resultados alcançados e as discussões. E por fim, a Seção 5 apresenta as conclusões e trabalhos futuros.

## 2 REVISÃO DE LITERATURA

Para avaliar o estado atual da implementação de Inteligência Artificial (IA) em sistemas de automação industrial utilizando ferramentas *low-code*, foi realizada uma revisão bibliográfica abrangendo os últimos cinco anos. O escopo dessa revisão inclui estudos que abordam a integração entre sistemas de automação e tecnologia da informação, com ênfase na adoção de tecnologias que simplificam o processo de desenvolvimento no contexto da Indústria 4.0. A busca bibliográfica foi conduzida em fontes acadêmicas e técnicas, como periódicos da SCieLO, Scopus, a Base de Dados de Teses e Dissertações (BDTD), o Portal de Periódicos da CAPES, Google Scholar, além de conferências e documentos técnicos de empresas atuantes nesse campo.

No que tange aos resultados obtidos na pesquisa, merece destaque o estudo conduzido por Sanchis *et al.* (2019), que explora o potencial das plataformas de desenvolvimento *low-code* na transformação digital da indústria, com enfoque nas características essenciais dessas plataformas e sua aplicabilidade na indústria de manufatura. O estudo também aponta a carência de funcionalidades específicas nas plataformas existentes, propondo um novo framework *low-code* voltado para o desenvolvimento ágil de aplicativos industriais.

Por outro lado, o estudo de Ihirwe (2023) investiga o estado da arte das plataformas de engenharia de baixo código, especialmente no contexto da Internet das Coisas (IoT – Internet of Things). Nesse sentido, destaca-se a necessidade urgente de ferramentas eficientes para lidar com a complexidade dos sistemas IoT, propondo abordagens de engenharia *low-code* para enfrentar esses desafios. O autor também apresenta um modelo de qualidade para avaliar plataformas de engenharia de baixo código.

Ainda, merece destaque o trabalho de Ren (2022), que propõe uma estrutura denominada SeLoC-ML para o desenvolvimento ágil de aplicativos de aprendizado de máquina na IoT industrial, utilizando tecnologias semânticas da web. O estudo enfatiza a importância das ferramentas de baixo código na simplificação do desenvolvimento de aplicativos de machine learning na IoT, demonstrando a eficácia do SeLoC-ML na redução do esforço de engenharia quando comparado às abordagens tradicionais.

Comparativamente, o presente trabalho busca integrar sistemas de visão computacional com automação industrial utilizando ferramentas *low-code*, como o Teachable Machine para o desenvolvimento de modelos de IA, e o Node-RED como plataforma de integração. Enquanto estudos anteriores exploram diferentes aspectos da aplicação de

ferramentas low-code em diversos domínios industriais, o trabalho proposto concentra-se na integração específica de sistemas de visão computacional com automação industrial, simplificando o processo de desenvolvimento e integração de sistemas complexos. Essa abordagem promove uma operação mais eficiente e simplificada, reduzindo a complexidade do desenvolvimento de modelos de IA e facilitando a integração com sistemas industriais heterogêneos. Assim, o estudo atual contribui para a expansão do uso de ferramentas low-code em cenários industriais específicos, alinhando-se com a evolução contínua da Indústria 4.0.

Em síntese, os estudos revisados ressaltam a importância da abordagem low-code na integração e manutenção de sistemas de automação industrial. Contudo, nota-se uma lacuna na literatura quanto ao desenvolvimento e à implementação de sistemas de IA no contexto de automação industrial por meio de uma abordagem totalmente low-code, que constitui o objetivo central deste trabalho.

### 3 METODOLOGIA

Nesta Seção, será apresentada a metodologia adotada para alcançar os objetivos deste estudo, que envolvem a implementação de um sistema de visão computacional com controle por Inteligência Artificial (IA), utilizando ferramentas low-code para o seu desenvolvimento e integração com a automação industrial. A metodologia proposta visa estruturar e implementar o uso de IA de maneira eficaz, simplificando sua complexidade. Em seguida, serão descritos os materiais e as tecnologias utilizadas para atingir os objetivos estabelecidos.

#### 3.1 Tecnologias e ambiente de testes

Para atingir os objetivos deste trabalho com a metodologia proposta, serão utilizadas em um ambiente de testes as seguintes tecnologias:

**a) Inteligência Artificial** por meio de técnicas de visão computacional, tecnologia habilitadora para a indústria 4.0 que vem se destacando na área da automação, devido ao uso de conjuntos de imagens (datasets) para treinar algoritmos que podem detectar objetos, reconhecer padrões, realizar controles de qualidade e executar tarefas visuais de alta complexidade (Milano; Honorato, 2014);

**b) Node-Red:** plataforma low-code de código aberto baseada em Node.js que funciona como um elo integrador entre a automação industrial e tecnologias da informação, permitindo que desenvolvedores conectem dispositivos, Application Programming Interface (API) e serviços online de uma maneira intuitiva e rápida (Node-Red, 2024; Alves e Alcalá, 2022);

**c) Teachable Machine:** ferramenta low-code web do Google que permite treinar modelos de machine learning para classificação. Possui uma interface intuitiva, coleta dados por meio de câmeras ou webcams e os usa para treinar modelos de redes neurais para a classificação de objetos em imagens, vídeos ou áudio, podendo classificar novos dados em tempo real. Além disso, a plataforma viabiliza a exportação dos modelos treinados para linguagens de programação como o JavaScript, por exemplo, permitindo a integração com outras tecnologias.

**d) Bancada Smart 4.0:** bancada educacional para o ensino das tecnologias habilitadoras da Indústria 4.0. A Smart 4.0 integra tecnologias de automação clássicas, como

programação de Controlador Lógico Programável (CLP), protocolos industriais, Interface Homem – Máquina (IHM), rastreabilidade RFID, múltiplos protocolos de comunicação, Internet Industrial das Coisas (IIoT – Industrial Internet of Things), integração com algumas funções dos Sistemas de Execução de Manufatura (MES) e robótica colaborativa (Labtronix, 2024).

### 3.2 Ambiente de testes

O ambiente de testes implementado no laboratório foi composto pelos seguintes dispositivos: (i) um dispositivo para coleta das imagens, uma webcam Full HD 1080p; (ii) um dispositivo para processamento dos dados e virtualização do Node-RED, um notebook configurado com processador Intel Core i7 115H, 16 GB de memória DDR5 e GPU NVIDIA RTX A500 com 6 GB de memória dedicada; e (iii) uma conexão Ethernet de 100 GB à internet, utilizada para o treinamento de modelos de IA no Teachable Machine.

### 3.3 Arquitetura

O funcionamento do sistema da bancada Smart 4.0 é notavelmente complexo, envolvendo diversos módulos que coordenam um processo produtivo único: a montagem de um bloco com seis faces personalizáveis. O processo tem início com a recepção de pedidos por meio de uma loja virtual. A bancada Smart 4.0 é responsável pela separação, preparação das peças, montagem e armazenamento em expedição dos blocos montados. Cada etapa é controlada por CLPs distintos, enquanto a orquestração é conduzida por uma aplicação principal. Embora a bancada possua rastreabilidade e um sistema de visão para inspeção da cor das peças montadas, ainda carece de um sistema para identificar montagens incorretas das lâminas nos blocos, não possuindo um sistema de inspeção de qualidade autônomo.

A metodologia proposta visa desenvolver e implementar um sistema de visão computacional de baixo custo, utilizando as tecnologias descritas no item 3.1. Este sistema funcionará como um subsistema auxiliar e independente da bancada Smart 4.0, focado no controle da qualidade das montagens dos blocos. O objetivo é permitir que a bancada atenda ao último requisito do índice de maturidade da Acatech — a adaptabilidade. A implementação desse sistema não interferirá na operação normal da bancada, mas proporcionará a detecção de montagens incorretas das lâminas, contribuindo para a melhoria da qualidade e da eficiência do processo de produção. A seguir, a Figura 1 apresenta o ambiente de implementação, juntamente com a bancada Smart 4.0 e o bloco personalizável que ela produz.

**Figura 1. Ambiente de implementação junto à bancada Smart 4.0.**




Fonte: elaborada pelo autor (2024).

### 3.3.1 Modelo de visão computacional com Teachable Machine

O desenvolvimento convencional de sistemas de visão computacional, utilizando abordagens de codificação hard-code, envolve um processo complexo e exigente, que demanda profundo conhecimento em programação e algoritmos de aprendizado de máquina (Solem, 2012). A prática de hard-code consiste na escrita direta e específica de código para uma tarefa ou aplicação, exigindo familiaridade avançada com a linguagem de programação e os conceitos subjacentes. Em contrapartida, o Teachable Machine do Google oferece uma alternativa simplificada e acessível, permitindo a criação de modelos de aprendizado de máquina sem a necessidade de codificação.

O conjunto de dados utilizado no Teachable Machine será composto por duas classes: "montagens corretas" e "montagens incorretas", relacionadas à montagem de um bloco com seis faces personalizáveis realizado pela bancada Smart 4.0. Essas categorias serão empregadas para treinar o modelo de aprendizado de máquina, capacitando-o a classificar novas imagens posteriormente. A Figura 2 apresenta uma amostra do conjunto de imagens utilizadas no treinamento, nas quais todas as faces do bloco estão posicionadas corretamente, caracterizando uma montagem correta.


**Figura 2. Conjunto de imagens que caracterizam uma montagem correta do bloco personalizável.**



Fonte: elaborada pelo autor (2024).

Por outro lado, a Figura 3 apresenta um extrato do conjunto de imagens caracterizando montagens incorretas, no qual algumas faces do bloco estão mal posicionadas ou então inexistentes.

**Figura 3. Conjunto de imagens que caracterizam uma montagem incorreta do bloco personalizável.**



Fonte: elaborada pelo autor (2024).

O processo de treinamento no Teachable Machine é acessível e simplificado, dispensando a necessidade de habilidades avançadas em programação. Inicialmente, os

usuários são orientados a coletar dados por meio de sua câmera, capturando imagens ou vídeos dos objetos ou elementos que desejam classificar. Em seguida, a ferramenta oferece uma interface intuitiva para rotular esses dados, atribuindo as categorias desejadas. Após a rotulação, o usuário inicia o processo de treinamento do modelo, que ocorre de forma automática e transparente. Durante o treinamento, o Teachable Machine aplica técnicas de aprendizado de máquina para ajustar os parâmetros do modelo com base nos dados fornecidos, sem exigir intervenção manual do usuário. Ao final do processo, o modelo está pronto para ser testado e utilizado para classificar novos dados em tempo real.

Neste trabalho, o modelo de visão computacional foi treinado e configurado para distinguir entre duas classes: "montagens corretas" e "montagens incorretas", simulando um sistema de controle de qualidade para a manufatura do bloco personalizável. O treinamento do modelo foi realizado com 792 imagens, sendo 315 para a classe de montagens corretas e 477 para a classe de montagens incorretas. A divisão das imagens entre as classes foi feita de forma a priorizar a detecção de montagens incorretas, considerando a maior complexidade dessa tarefa e a necessidade de um número maior de amostras para garantir que o modelo aprendesse adequadamente os padrões dessa classe. O modelo foi parametrizado com 100 épocas, tamanho de lote (*batch size*) de 32 e taxa de aprendizado de 0,001, parâmetros que se mostraram eficientes para o processo de captura e avaliação das imagens. A escolha de 100 épocas foi baseada na necessidade de permitir ao modelo tempo suficiente para aprender os padrões nas imagens e ajustar seus pesos adequadamente, enquanto a performance foi monitorada para evitar *overfitting*. A taxa de aprendizado de 0,001 foi escolhida por ser um valor inicial conservador, permitindo ao modelo ajustar seus pesos de maneira suave e eficiente, evitando grandes saltos durante o treinamento que poderiam prejudicar a convergência. O tamanho de lote de 32 foi selecionado como um valor intermediário, equilibrando eficiência computacional e capacidade de generalização. Tamanhos de lote maiores poderiam acelerar o treinamento, mas também aumentariam o risco de *overfitting*, especialmente com um número relativamente pequeno de imagens. A combinação desses parâmetros contribuiu para um treinamento eficiente, com boa capacidade de generalização para as diferentes condições das montagens. A metodologia proposta para o desenvolvimento do modelo de visão computacional com o Teachable Machine evidencia a transformação no desenvolvimento entre abordagens convencionais de codificação hard-code para a simplicidade e acessibilidade proporcionadas pelo Teachable Machine do Google.

### 3.3.2 Integração com a automação via Node-Red

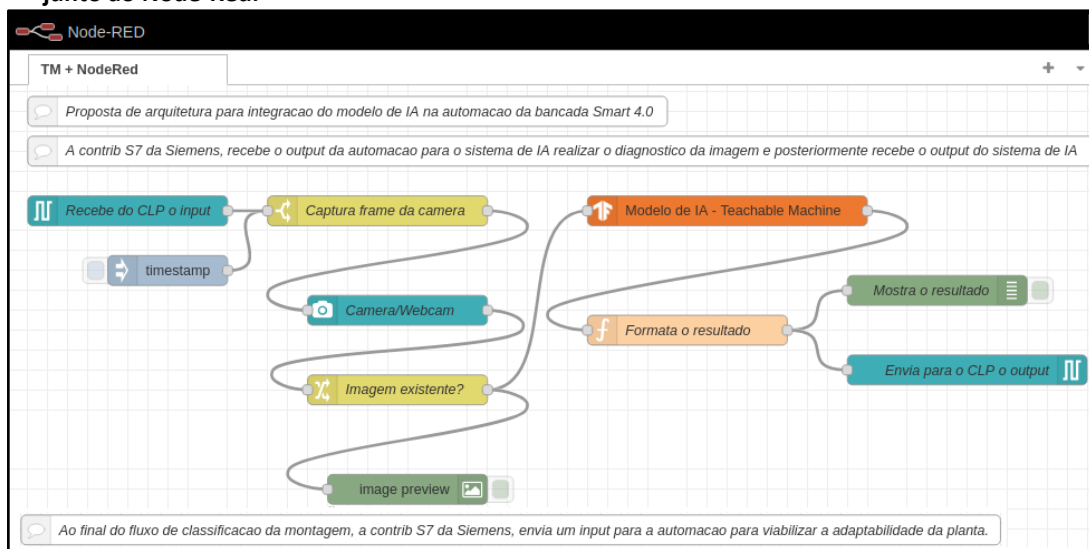
A integração de sistemas de Inteligência Artificial (IA) à automação industrial tem se tornado um tema de interesse crescente, com o objetivo de otimizar processos, aumentar a eficiência e impulsionar a inovação nas operações industriais. Uma abordagem eficaz para essa integração é o uso de ferramentas de desenvolvimento low-code, como o Node-Red (Node-Red, 2024; Alves e Alcalá, 2022). O Node-Red é uma plataforma de programação visual de código aberto baseada em JavaScript, que facilita a criação de fluxos de trabalho automatizados por meio de uma interface gráfica intuitiva.

Atuando como um orquestrador entre a Tecnologia da Informação (TI) e a Tecnologia da Automação (TA), o Node-Red simplifica a integração de sistemas de IA com dispositivos e sistemas de automação industrial. A bancada Smart 4.0, por exemplo, mantém a sinergia entre TI e TA por meio do Node-Red, que gerencia fluxos de automação conectando diferentes

dispositivos e serviços. Com uma vasta biblioteca de nós pré-configurados, que representam diversos dispositivos e serviços, o Node-Red facilita a integração entre sistemas heterogêneos, garantindo a comunicação e troca de dados de forma transparente. Além disso, o Node-Red permite integrar serviços de IA, como processamento de linguagem natural, reconhecimento de padrões e aprendizado de máquina, possibilitando a implementação de funcionalidades avançadas de IA em ambientes industriais.

Neste trabalho, um dos objetivos principais é assegurar a integração do modelo de IA treinado no Teachable Machine com a automação industrial via Node-Red. Após o treinamento, o modelo foi exportado para código JavaScript, o que viabilizou sua integração ao ambiente Node-Red. Utilizando funções pré-configuradas, o modelo de IA foi incorporado aos fluxos de automação do Node-Red, transformando-se em uma ferramenta de controle de qualidade para o processo de montagem do bloco personalizável da bancada Smart 4.0. Essa integração proporcionou uma abordagem mais dinâmica e adaptável na detecção de montagens corretas e incorretas, contribuindo para a otimização e eficiência do processo industrial. A Figura 4 ilustra o fluxo desenvolvido para implementar o modelo de IA, criado no Teachable Machine, dentro do Node-Red, com o objetivo de orquestrar a interação entre os sistemas de TI e TA. Este fluxo utiliza uma biblioteca (ou contribs) que oferece funcionalidades para conectar especificamente com os controladores lógicos programáveis da Siemens, empregados pela Smart 4.0.

**Figura 4. Fluxo desenvolvido para a implementação do modelo de IA, criado no Teachable Machine, junto ao Node-Red.**



Fonte: elaborada pelo autor (2024).

A metodologia proposta para a integração do modelo de IA do Teachable Machine à automação industrial por meio do Node-Red é fundamentada na exportação do modelo para JavaScript e sua incorporação nos fluxos de automação. Essa abordagem low-code visa simplificar a implementação e a orquestração entre os sistemas de TI e TA, oferecendo uma solução acessível e eficiente para o controle de qualidade na bancada Smart 4.0. Além disso, o uso do Node-Red facilita a colaboração entre profissionais de diferentes áreas, promovendo a integração de soluções de IA no contexto da Indústria 4.0, e permitindo uma implementação mais ágil e adaptável a diferentes cenários industriais.

#### 4 RESULTADOS E DISCUSSÕES

Para simplificar a complexidade das aplicações de Inteligência Artificial (IA) na automação industrial, este trabalho apresenta uma abordagem inovadora utilizando a bancada educacional Smart 4.0. A abordagem proposta envolve a utilização de duas ferramentas low-code de baixa complexidade: a) Teachable Machine, para o desenvolvimento do modelo de visão computacional voltado para a inspeção de qualidade em uma etapa do processo de manufatura realizado pela bancada Smart 4.0; e b) Node-Red, para a integração do modelo de IA com a automação industrial existente. Essa integração permite uma operação eficiente e simplificada, onde a automação e a IA trabalham em conjunto para otimizar o desempenho produtivo da bancada Smart 4.0.

Essa abordagem evidencia a construção de modelos de visão computacional por meio de técnicas de IA de forma facilitada, uma vez que o Teachable Machine se mostrou uma ferramenta de baixa complexidade e intuitiva. O usuário não necessita de registro e consegue, em poucos passos, criar modelos inteligentes de classificação. Em uma abordagem tradicional, essa tarefa exigiria conhecimentos profundos em modelagem matemática, estatística, estrutura de dados e linguagens de programação. A abstração desses conhecimentos por meio de uma ferramenta low-code permite que profissionais da área de automação industrial implementem IA em suas soluções de maneira acessível.

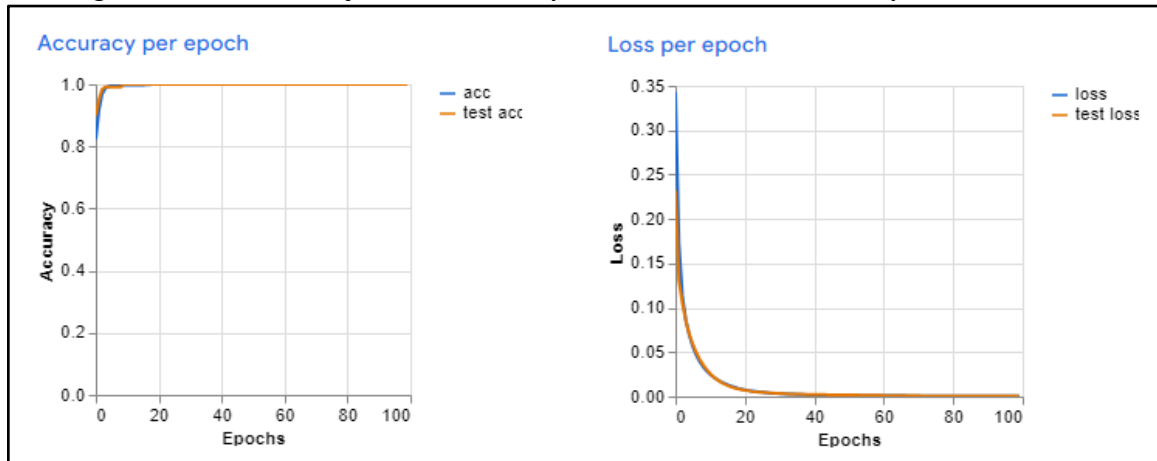
Neste contexto, o trabalho também apresenta uma abordagem de integração utilizando o Node-Red, outra ferramenta low-code. A integração entre as áreas de tecnologia da informação e automação nem sempre é harmônica, pois exige conhecimentos técnicos em diversas tecnologias, hardwares específicos, protocolos de comunicação e bancos de dados. A utilização de uma ferramenta low-code facilita essa integração, abstraindo a complexidade desses conhecimentos e acelerando a adoção das tecnologias habilitadoras da Indústria 4.0.

Durante a execução do processo de montagem do bloco personalizável, o programa que orquestra a execução entre os módulos da bancada Smart 4.0 é um CLP, que divide este processo em etapas como solicitação de montagem, separação dos suprimentos, posicionamento do bloco, busca e encaixe das peças, e expedição final. A integração do modelo de IA ao processo existente foi realizada por meio da comunicação com este CLP. Na camada de Tecnologia da Informação (TI), foi implementado um bloco para monitorar o estado da montagem no CLP, acionando um fluxo de ações no Node-Red para acionar o sistema de IA e verificar a montagem do bloco antes da etapa de expedição. Esse fluxo inclui a captura e o processamento de imagens, execução do modelo de IA e tratamento dos resultados, conforme apresentado na Figura 8.

A comunicação entre a automação e a IA foi realizada via protocolo ISO/TCP, utilizando variáveis booleanas para troca de dados. Essa abordagem simplifica o gerenciamento do modelo de IA, permitindo uma operação flexível. O modelo de IA foi executado em um contêiner Docker gerenciado pelo Node-Red, com um fluxo personalizado para receber as imagens, processá-las e classificá-las como "montagens corretas" ou "montagens incorretas", adicionando à bancada Smart 4.0 um sistema de controle de qualidade.

Durante o processo de treinamento, o Teachable Machine oferece informações detalhadas sobre o desempenho do modelo de visão computacional, como acurácia, perda e a matriz de confusão. A Figura 5 apresenta o gráfico das funções de acurácia e perda do modelo de visão computacional, fornecendo uma representação visual do desempenho do modelo ao longo do treinamento.

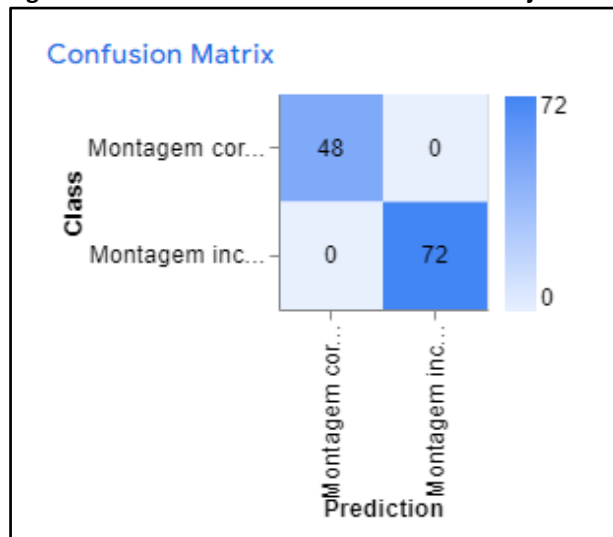
Figura 5. Gráfico das funções de acurácia e perda do modelo de visão computacional.



Fonte: elaborada pelo autor (2024).

A Figura 6 apresenta os dados da matriz de confusão, fornecendo uma análise detalhada do desempenho do modelo na classificação das amostras de teste. O modelo apresentou uma excelente performance, atingindo 100% de acurácia no conjunto de testes. No entanto, é importante ressaltar que, em aplicações práticas, é incomum que modelos alcancem 100% de acurácia devido à complexidade dos ambientes reais. No contexto deste experimento controlado, porém, os resultados atenderam satisfatoriamente aos objetivos propostos.

Figura 6. Matriz de confusão do modelo no conjunto de testes.

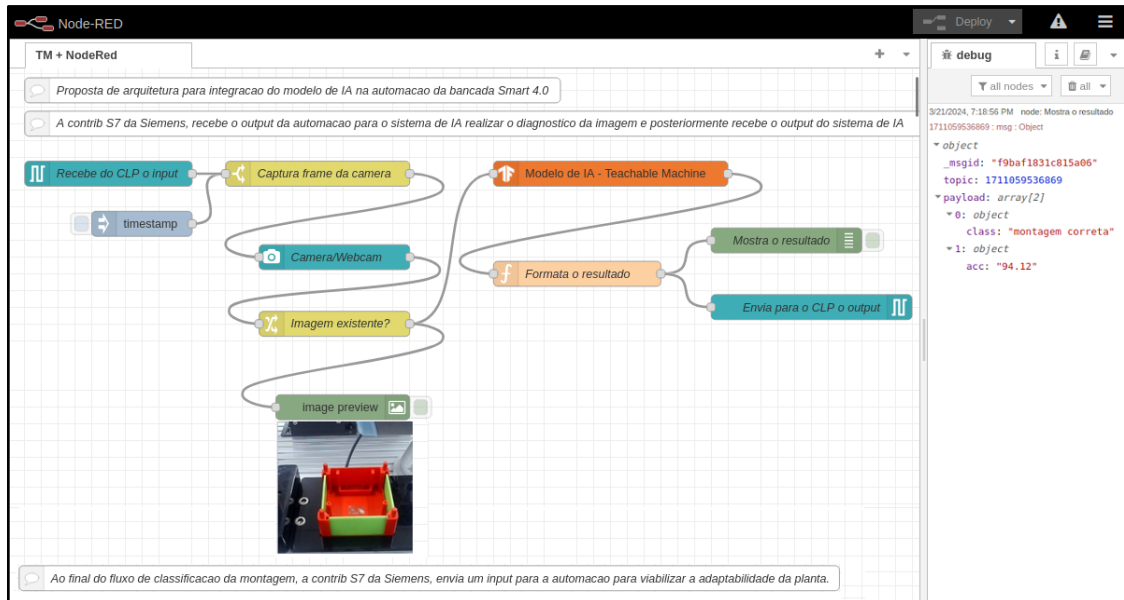


Fonte: elaborada pelo autor (2024).

Além disso, durante a fase de testes, foi parametrizado um filtro delimitando como aceitável, apenas classificações maiores que 70% de confiança. Esse tipo de filtro em sistemas de IA é comum, pois determinam níveis aceitáveis de distinção entre as classes, uma vez que abaixo disso, o nível de incerteza aumenta. A Figura 7 apresenta o fluxo de integração entre o modelo de IA e automação no Node-Red para a classificação de um bloco considerado montado corretamente. Neste caso, após o recebimento desta informação no CLP da bancada

Smart 4.0, a automação pode avançar para a próxima etapa do processo de manufatura, a expedição.

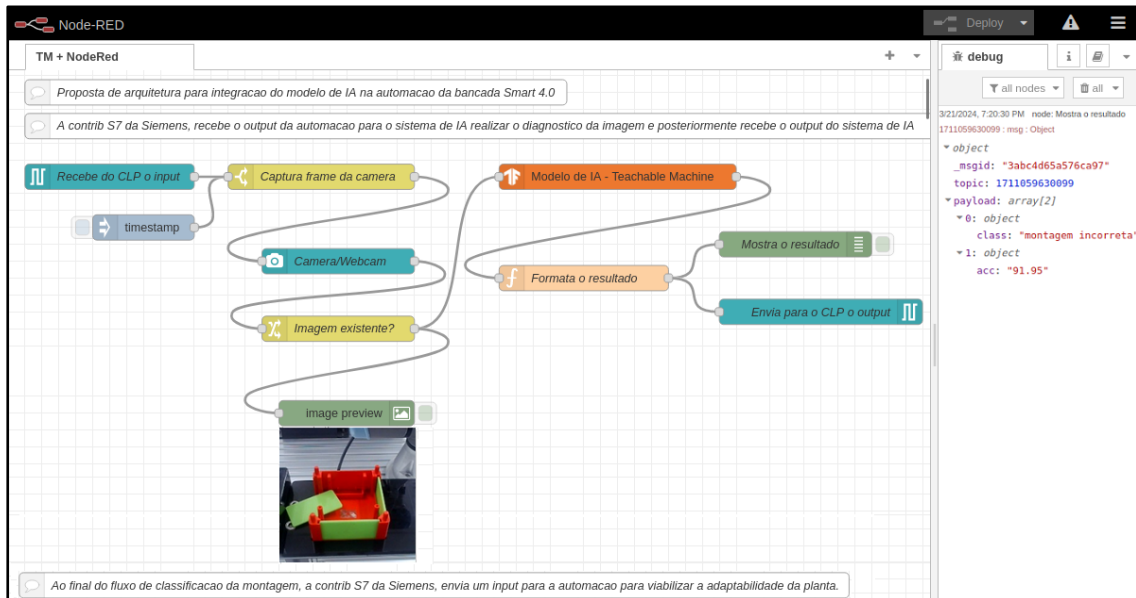
**Figura 7. Fluxo de classificação no Node-Red de um bloco considerado montado corretamente pelo modelo de IA.**



Fonte: elaborada pelo autor (2024).

No entanto, caso a montagem seja classificada como incorreta pelo modelo de IA, a automação pode iniciar uma série de ações para resolver esse problema, como por exemplo: a) disparar uma *trigger* (acionamento) para a automação, solicitando que o robô refaça a tarefa; b) parar o processo e enviar uma mensagem, via IHM (Interface Homem Máquina), para que o operador corrija o problema manualmente e retome o processo; c) rotular esse bloco, por meio da gravador RFID (*Radio Frequency Identification*) como um bloco que deve ser descartado no módulo de expedição. A Figura 8 apresenta o fluxo de integração entre o modelo de IA e automação no Node-Red para a classificação de um bloco considerado montado incorretamente.

**Figura 8. Fluxo de integração entre o modelo de IA e automação no Node-Red para a classificação de um bloco considerado montado incorretamente.**



Fonte: elaborada pelo autor (2024).

Os desafios enfrentados nesta pesquisa abrangem desde a fase de treinamento do modelo de IA até a implementação da abordagem low-code na automação existente. Durante o treinamento do modelo de IA, foram identificadas variações no posicionamento da câmera e nas condições de iluminação das imagens capturadas, o que afetou a qualidade do treinamento. Para mitigar essas variações, foram aplicados filtros de imagem em diferentes escalas, com o objetivo de reduzir o impacto dessas mudanças nas imagens capturadas pela câmera.

No que diz respeito à implementação da abordagem proposta na automação existente, um desafio intrínseco identificado refere-se ao tempo de resposta necessário para operações rápidas e assertivas, evitando fluxos redundantes e exceções desnecessárias. Embora esse desafio não tenha se manifestado no cenário atual, devido à bancada Smart 4.0 ser um ambiente controlado e educacional, é importante destacar que, em aplicações industriais, frequentemente são exigidos tempos de resposta curtos, da ordem de milissegundos.

Por fim, os principais resultados obtidos na implementação da metodologia proposta são: a) a abstração da complexidade do desenvolvimento e da operacionalização de um modelo de visão computacional, baseado em técnicas de IA, por meio do uso da ferramenta low-code Teachable Machine; b) a integração harmoniosa entre a Tecnologia da Informação (TI) e a Tecnologia da Automação (TA), utilizando o Node-Red e o protocolo de comunicação ISO/TCP para uma comunicação simplificada via CLP. A realização dessa integração foi facilitada pelo uso das ferramentas low-code Teachable Machine e Node-Red, que dispensam a necessidade de um conhecimento profundo em ambas as áreas, permitindo que profissionais de diferentes domínios colaborem na implementação de soluções de IA na automação industrial. Com interfaces intuitivas e abordagens simplificadas de desenvolvimento, tanto o Teachable Machine quanto o Node-Red tornaram viável a integração do modelo de IA com os fluxos de automação, possibilitando uma implementação mais ágil e eficiente. Essa sinergia entre as ferramentas low-code foi essencial para a democratização da tecnologia e para a promoção da inovação no contexto da Indústria 4.0.

## 5 CONCLUSÃO

O desenvolvimento e a implementação da metodologia proposta para a integração de sistemas de visão computacional com automação industrial representam um avanço significativo na simplificação e democratização da aplicação de tecnologias de Inteligência Artificial (IA) no contexto da Indústria 4.0. A abordagem low-code adotada, utilizando o Teachable Machine e o Node-Red, demonstrou ser eficaz na construção e integração de modelos de IA em uma bancada educacional de manufatura avançada, proporcionando uma operação eficiente e simplificada.

As considerações finais destacam a importância de abstrair a complexidade do desenvolvimento de modelos de visão computacional, os quais, tradicionalmente, exigem conhecimentos avançados em programação, algoritmos de aprendizado de máquina, modelagem matemática e estatística aplicada. O uso do Teachable Machine proporcionou uma alternativa acessível e intuitiva, permitindo que profissionais de diferentes áreas possam criar e implementar modelos de IA e integrá-los aos processos industriais. Além disso, a integração entre tecnologia da informação e tecnologia da automação, por meio do Node-Red, se mostrou uma abordagem eficaz para orquestrar a interação entre sistemas heterogêneos, facilitando a comunicação e troca de dados de forma transparente. O uso de protocolos de comunicação como o ISO/TCP permitiu uma integração simplificada entre o modelo de IA e o controlador lógico programável (CLP) da bancada Smart 4.0, garantindo uma operação dinâmica e flexível.

Entretanto, alguns desafios foram identificados durante o desenvolvimento e implementação da metodologia. Variações no posicionamento da câmera e nas condições de iluminação das imagens capturadas afetaram a qualidade do treinamento do modelo de IA, exigindo o uso de filtros de imagem para mitigar essas variações. Além disso, o tempo de resposta necessário para operações rápidas e assertivas na automação industrial representa um desafio importante, especialmente em aplicações industriais reais, que demandam tempos de resposta curtos e estáveis.

Existem várias oportunidades de aprimoramento que podem ser exploradas no contexto deste estudo. Uma delas é a investigação de outras tecnologias de visão computacional, mantendo a abordagem low-code atual. Isso inclui a possibilidade de treinar modelos de IA utilizando outras ferramentas, como Roboflow, Label Studio, *Computer Vision Annotation Tool* (CVAT), entre outras. Além disso, seria interessante desenvolver uma aplicação para armazenar registros de montagem, visando aprimorar o treinamento dos modelos. Esse registro permitiria ampliar o conjunto de dados disponíveis e reduzir o número de falsos positivos, melhorando a precisão do sistema. Outra perspectiva promissora seria a fixação da câmera no braço do robô, possibilitando a exploração de diferentes ângulos de captura de imagens. Isso permitiria avaliar o impacto desses ângulos no desempenho do sistema, potencialmente melhorando a detecção e classificação de objetos durante o processo de montagem.

## REFERÊNCIAS

ALVES, Fábio Ramos; ALCALÁ, Symone Gomes Soares. Análise da abordagem low-code como facilitador da transformação digital em indústrias. **Revista e-TECH: Tecnologias para Competitividade Industrial**, v. 15, n. 1, 2022.

AMERICAN NATIONAL STANDARD. **ANSI/ISA-95.00. 01**: enterprise-control system integration—part 1: models and terminology. Washington, DC: International Society of Automation, 2010.

BECKER, Tilman *et al.* **Industrie 4.0 maturity index**: managing the digital transformation of companies. Munich: Herbert Utz Verlag, 2017.

HACKATHORN, Richard. Minimizing action distance. **DM Review**, v. 12, p. 22-23, 2002.

IHIRWE, Felicien. **Low-code engineering for the Internet of Things**. Tese (Doutorado em Information and Communication Technology) - Department of Information Engineering, Computer Science and Mathematics - University of L'Aquila, 2023. Disponível em: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=4539001](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4539001). Acesso em: 14 jan. 2024.

LABTRONIX. Smart 4.0. Disponível em: <https://www.labtronix.com/smart-40/>. Acesso em: 12 fev. 2024.

LUCIO, João Paulo Duarte *et al.* **Análise comparativa entre arquitetura monolítica e de microsserviços**. TCC (Graduação) - Centro Tecnológico - Sistemas de Informação - Universidade Federal de Santa Catarina, Florianópolis, 2017. Disponível em: <https://repositorio.ufsc.br/xmlui/handle/123456789/182309>. Acesso em: 14 jan. 2024.

MILANO, Danilo; HONORATO, Luciano Barrozo. **Visão computacional**. Limeira: Universidade Estadual de Campinas – UNICAMP - Faculdade de Tecnologia, 2014.

MIT TECHNOLOGY. Ferramentas low-code: a simplificação da tecnologia como o segredo para a Transformação Digital. 03 junho 2022. Disponível em: <https://mittechreview.com.br/ferramentas-low-code-a-simplificacao-da-tecnologia-como-o-segredo-para-a-transformacao-digital>. Acesso em: 14 jan. 2024.

NODE-RED. IBM's emerging technology services. 2024. Disponível em: <https://nodered.org/about/>. Acesso em: 19 mar. 2024.

PERES, Ricardo Silva *et al.* Industrial artificial intelligence in industry 4.0-systematic review, challenges and outlook. **IEEE access**, v. 8, p. 220121-220139, 2020.

REN, Haoyu *et al.* Seloc-ml: semantic low-code engineering for machine learning applications in industrial IoT. **International Semantic Web Conference**. Cham: Springer International Publishing, 2022.

SANCHIS, Raquel *et al.* Low-code as enabler of digital transformation in manufacturing industry. **Applied Sciences**, v. 10, n. 1, p. 12, 2019.

SIEMENS. SIMATIC IOT2040. 2018. Disponível em: <https://assets.new.siemens.com/siemens/assets/api/uuid:7b2c5580-7436-4081-9ae6-7c4eba29ddd1/simaticiot2040.pdf>. Acesso em: 08 fev. 2024.

SOLEM, Jan Erik. **Programming computer vision with Python: tools and algorithms for analyzing images**. Sebastopol: O'Reilly Media, 2012.


WEICHERT, Dorina *et al.* A review of machine learning for the optimization of production processes. **The International Journal of Advanced Manufacturing Technology**, v. 104, n. 5-8, p. 1889-1902, 2019.

WILLIAMSON, S.; VIJAYAKUMAR, K. Artificial intelligence techniques for industrial automation and smart systems. **Concurrent Engineering**, v. 29, n. 3, p. 291-292, 2021.

### Sobre os Autores:

---

#### <sup>i</sup> Dhyonatan Santos de Freitas



Professor e coordenador de cursos superiores no Centro Universitário SENAI/SC - Campus Joinville (UniSENAI). Mestre em Computação Aplicada pela Universidade Federal do Pampa (2019). Bacharel em Ciência da Computação pela Universidade Federal do Pampa (2017). Experiência em processamento digital de imagens, machine learning, inteligência artificial, big data, data analytics, data science, indústria 4.0 e segurança da informação. ORCID ID: <https://orcid.org/0000-0002-4425-6409>

#### <sup>ii</sup> Miguel Bozer da Silva



Mestre em Engenharia de Informação pela Universidade Federal do ABC (2021) com graduação nas áreas de Tecnologia em Mecatrônica Industrial (2009) pela Faculdade de Tecnologia Termomecânica, Bacharelado em Ciência e Tecnologia (2017) pela Universidade Federal do ABC e Engenharia de Instrumentação Automação e Robótica (2019) na Universidade federal do ABC. Principal área de interesse para pesquisas é a aplicação de inteligência artificial. ORCID ID: <https://orcid.org/0000-0003-0793-7288>

**iii José Roberto dos Santos**

Possui Pós-graduação na área de segurança da informação pela Uninove (2016), graduação em tecnologia da informação e bacharel em sistema da informação (2009), além de superior em Automação industrial. Tem experiência na área de Segurança da informação, administração de ambientes de redes Windows e Linux, automação indústria, além de ministrar aulas de segurança da informação, IoT e análise de dados. ORCID ID: <https://orcid.org/0000-0002-5201-7731>

**iv Ricardo Martinez Vicentini**

Mestre em Engenharia Elétrica pela Universidade Federal do ABC - UFABC (2018), pós graduado *lato sensu* em Automação Industrial pela Faculdade SENAI de Tecnologia Mecatrônica (2016), Tecnólogo em Automação Industrial pela Faculdade de Tecnologia São Vicente (2013) e Técnico em Eletrônica pela Etec Aristóteles Ferreira (2009). Possui experiência nas áreas de Automação, Mecatrônica e Eletrônica, atuando nas seguintes linhas de pesquisa: Comunicação sem Fio para IIoT, Sistemas Microcontrolados e Inteligência Artificial aplicada em robótica e automação (com ênfase na Lógica Paraconsistente LPA2v e Algoritmos Genéticos). ORCID ID: <https://orcid.org/0000-0001-6974-0873>