

Classificação da qualidade e rastreabilidade logística de atum utilizando visão computacional

Quality classification and logistic traceability of tuna using computer vision

Artemísia Kimberlly Marques da Silva ¹

Ewerton Vasconcelos Lopes ²

Hilquias Abias Figueiredo Silva ³

João Roberto Chaves Camboim ⁴

Robinson Luis de Souza Alves ⁵

Ivanilson França Vieira Júnior ⁶

Diego da Silva Pereira ⁷

Resumo

Apesar de sua posição de destaque como exportador de proteína animal no mercado global, o setor pesqueiro brasileiro ainda enfrenta uma defasagem tecnológica nos processos de captura e gestão. A persistência de métodos tradicionais e manuais resulta frequentemente em falhas logísticas e ineficiências operacionais. Um dos principais gargalos da indústria é a escassez de mão de obra qualificada para realizar a classificação assertiva da qualidade do pescado, especificamente do Atum (*Thunnus albacares*). Além disso, a falta de controle no fluxo industrial gera atrasos significativos na entrega final. Diante deste cenário, propõe-se o desenvolvimento de um sistema capaz de realizar a classificação automática da qualidade visual do atum e o seu rastreamento ao longo de toda a cadeia produtiva, com o objetivo de otimizar a logística e reduzir o tempo de processamento e entrega, integrando técnicas de Visão Computacional, Internet das Coisas (IoT) e *Edge Computing*. O projeto contempla a captura padronizada de imagens, o treinamento de modelos de IA baseados em tensores e o envio dos metadados para ambiente em nuvem via protocolo HTTP. A abordagem metodológica adotada no desenvolvimento dessa produção é a *Design Science Research* (DSR) que visa a criação de um artefato tecnológico sendo esse um software de visão computacional que se propõe a resolver um problema prático no contexto da indústria pesqueira.

Palavras-chave: Visão Computacional; IoT; Atum; Edge Computing; Indústria 4.0.

¹ Discente do Curso de Formação Inicial e Continuada (Curso FIC) em Residência Tecnológica em Software Embarcado, na modalidade a distância. e-mail: artemisiakmds@gmail.com.br

² Discente do Curso de Formação Inicial e Continuada (Curso FIC) em Residência Tecnológica em Software Embarcado, na modalidade a distância. e-mail: ewerton.va.lopes@gmail.com.br

³ Discente do Curso de Formação Inicial e Continuada (Curso FIC) em Residência Tecnológica em Software Embarcado, na modalidade a distância. e-mail: hilquias.dev@gmail.com

⁴ Discente do Curso de Formação Inicial e Continuada (Curso FIC) em Residência Tecnológica em Software Embarcado, na modalidade a distância. e-mail: devjoaoroberto@gmail.com

⁵ Docente do Curso de Formação Inicial e Continuada (Curso FIC) em Residência Tecnológica em Software Embarcado, na modalidade a distância. e-mail: robinson.alves@ifrn.edu.br

⁶ Docente do Curso de Formação Inicial e Continuada (Curso FIC) em Residência Tecnológica em Software Embarcado, na modalidade a distância. e-mail: ivanilson.junior@ifrn.edu.br

⁷ Docente do Curso de Formação Inicial e Continuada (Curso FIC) em Residência Tecnológica em Software Embarcado, na modalidade a distância. e-mail: diego.pereira@ifrn.edu.br

Abstract

Despite its prominent position as an exporter of animal protein in the global market, the Brazilian fishing industry still faces a technological gap in capture and management processes. The persistence of traditional and manual methods frequently results in logistical failures and operational inefficiencies. One of the main bottlenecks in the industry is the shortage of qualified labor capable of accurately classifying fish quality, specifically Yellowfin Tuna (*Thunnus albacares*). Furthermore, the lack of control throughout the industrial flow generates significant delays in final delivery. In light of this scenario, this study proposes the development of a system capable of automatically classifying the visual quality of tuna and tracking it throughout the entire production chain, aiming to optimize logistics and reduce processing and delivery time through the integration of Computer Vision, the Internet of Things (IoT), and Edge Computing techniques. The project includes standardized image acquisition, the training of AI models based on tensors, and the transmission of metadata to a cloud environment via the HTTP protocol. The methodological approach adopted in this study is Design Science Research (DSR), which focuses on the creation of a technological artifact, namely a computer vision software designed to solve a practical problem within the context of the fishing industry.

Keywords: Computer Vision; IoT; Tuna; Edge Computing; Industry 4.0.

1 INTRODUÇÃO

A indústria pesqueira desempenha um papel importante na segurança alimentar e na economia de vários países. No Brasil, dada a extensão da costa e biodiversidade marinha conferem ao setor um potencial estratégico e destaca-se na captura e exportação de diversas espécies, incluindo o Atum (*Thunnus albacares*). Para atender às demandas de um mercado que prioriza não apenas a quantidade, mas também a qualidade do pescado, a eficiência na cadeia de produção torna-se uma necessidade cada vez mais tangente ao processo.

Apesar desse potencial, o Brasil ainda enfrenta dificuldades significativas na pesca e gestão, particularmente quando analisadas sob uma perspectiva tecnológica. Uma das etapas críticas é a classificação da qualidade do pescado e a organização logística dentro das empresas, atividades realizadas majoritariamente de forma manual. Essa dependência da avaliação humana traz consigo diversos problemas derivados, sejam eles a subjetividade na análise visual da qualidade, pois cada avaliador terá uma validação; a escassez de trabalhadores especializados na área; a fadiga dos operadores e a inconsistência na

padronização. Quanto à logística de armazenamento, o trabalho manual gera gargalos de tempo onde a demora na definição do destino correto para cada lote pode comprometer a vida útil do peixe e sua qualidade, uma vez que o produto precisa ser mantido refrigerado para preservar seu frescor.

Neste cenário, a indústria 4.0 e as tecnologias de visão computacional surgem como ferramentas capazes de mitigar essas ineficiências, pois a capacidade de algoritmos processar imagens com rapidez e precisão valiosas nesse processo criando uma análise objetiva e padronizada das características a serem classificadas.

1.1 Objetivos

O objetivo geral deste trabalho é desenvolver um sistema inteligente dividido em duas etapas: a classificação automática da qualidade do atum e o rastreamento contínuo dos peixes na linha de produção, integrando dispositivos de borda (Edge Computing) com armazenamento em nuvem.

Para alcançar este propósito, definem-se os seguintes objetivos específicos:

- Implementar um aplicativo para fazer a captura das imagens, listagens e classificação dos pescados.
- Desenvolver e treinar modelos de Inteligência Artificial baseados em tensores para classificar cortes de carne (rabo e sashibo) e identificar padrões de qualidade.
- Criar um algoritmo de rastreamento capaz de monitorar a movimentação dos atuns desde a mesa de manipulação até o encaixotamento ou armazenamento em câmara fria.
- Estabelecer uma arquitetura de comunicação sem fio (Wi-Fi) utilizando protocolo HTTP para transmissão eficiente de dados entre as unidades de processamento local e o banco de dados em nuvem.

1.2 Justificativa

A escolha por uma abordagem baseada em Visão Computacional e IoT justifica-se pela necessidade de padronização e escalabilidade no processo industrial. A inspeção visual humana, embora tradicional, é suscetível à fadiga e à subjetividade. A utilização de redes neurais e processamento de tensores permite uma classificação consistente baseada em padrões matemáticos extraídos das imagens.

Além disso, a arquitetura proposta, que utiliza dispositivos mobile, deixam o sistema simples de replicação sendo necessário apenas instalação do aplicativo além de mais simples de usar para o usuário final, protocolos web padrão (HTTP) e armazenamento em nuvem, garantindo que os dados de rastreabilidade estejam acessíveis remotamente para auditoria e

gestão. Essa integração tecnológica promove modernização de baixo custo e alta eficiência para o chão de fábrica.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo dedica-se à exposição dos conceitos e princípios tecnológicos que sustentam o desenvolvimento do sistema proposto. A base teórica percorre desde os fundamentos da inteligência artificial e visão computacional até as camadas de comunicação e armazenamento, essenciais para a viabilidade de uma solução industrial integrada.

2.1 Inteligência Artificial e Visão Computacional

A Inteligência Artificial (IA) consolidou-se como o campo da ciência da computação voltado ao desenvolvimento de sistemas que mimetizam a capacidade humana de tomada de decisão e resolução de problemas. Segundo Russell e Norvig (2013), a visão moderna da IA foca na criação de agentes racionais, capazes de processar percepções do ambiente e executar ações que maximizem as chances de sucesso de um objetivo específico. No contexto deste trabalho, a Visão Computacional atua como o subcampo da IA responsável por interpretar o mundo físico por meio de entradas visuais, transformando imagens capturadas por sensores digitais em dados compreensíveis para algoritmos de processamento.

2.1.1 Tensores e Processamento de Imagens

A operacionalização da visão computacional em modelos de *Deep Learning* exige que os dados visuais sejam estruturados de forma matemática rigorosa. Conforme explicam Goodfellow, Bengio e Courville (2016), essa representação ocorre por meio de tensores, que são generalizações multidimensionais de matrizes. Enquanto uma imagem em tons de cinza pode ser representada por um tensor de segunda ordem (uma matriz de duas dimensões), as imagens coloridas capturadas em ambientes industriais exigem tensores de terceira ordem, que compreendem a altura, a largura e os três canais de cor do sistema RGB. O processamento desses tensores por Redes Neurais Convolucionais (CNNs) é o que possibilita a extração automática de características complexas para a classificação e segmentação de objetos.

2.2 Comunicação de Dados: Wi-Fi e HTTP

A conectividade representa o pilar de integração entre o hardware de captura e o

sistema de análise centralizado. Para viabilizar a mobilidade dos sensores no chão de fábrica, utiliza-se a tecnologia Wi-Fi, baseada no padrão IEEE 802.11. Tanenbaum e Wetherall (2011) ressaltam que as redes locais sem fio (WLAN) eliminam a necessidade de infraestruturas cabeadas extensas, permitindo que dispositivos de rastreamento se desloquem livremente pela unidade fabril sem perda de conexão.

Complementarmente à infraestrutura física, o protocolo HTTP atua na camada de aplicação para garantir o tráfego das informações. Segundo Fielding *et al.* (1999), o HTTP opera sob um modelo cliente-servidor, sendo amplamente adotado em arquiteturas modernas devido à sua natureza *stateless* e versatilidade em operações de transferência de dados. No escopo de sistemas IoT, a utilização de requisições HTTP em conjunto com APIs RESTful permite que os dispositivos de borda enviem resultados de processamento para servidores remotos de maneira eficiente e padronizada.

2.3 Computação em Nuvem e Bancos de Dados

A eficiência de um ecossistema baseado em visão computacional e Internet das Coisas (IoT) é intrinsecamente dependente da robustez da arquitetura que sustenta o fluxo de dados. No cenário industrial, onde a captura de imagens e o rastreamento de ativos geram um volume contínuo e heterogêneo de telemetria, a gestão da informação deve transcender o simples armazenamento local. Torna-se imperativo estabelecer uma infraestrutura que harmonize o processamento de alto desempenho com protocolos de persistência que garantam a integridade e disponibilidade dos dados a longo prazo. Nesse sentido, a convergência entre a computação em nuvem e sistemas gerenciadores de bancos de dados constitui o alicerce necessário para suportar a escalabilidade operacional, permitindo que o sistema evolua de um protótipo isolado para uma solução corporativa resiliente e segura.

2.3.1 Computação em Nuvem

A computação em nuvem, conforme definida por Mell e Grance (2011), oferece acesso sob demanda a um conjunto compartilhado de recursos computacionais configuráveis, como redes, servidores e armazenamento. No contexto deste projeto, essa tecnologia é fundamental pois permite que o sistema de análise de pescado apresente escalabilidade elástica: à medida que o volume de produção e a quantidade de câmeras na fábrica aumentam, a infraestrutura de nuvem absorve a carga adicional sem a necessidade de intervenções físicas ou grandes investimentos em hardware local. Além disso, a centralização dos dados na nuvem facilita a integração com outros sistemas de gestão empresarial (ERP), consolidando a visão analítica da

planta fabril em tempo real.

2.3.2 Bancos de Dados

Para garantir que o histórico de classificação e as coordenadas de rastreamento sejam mantidos de forma organizada e recuperável, utilizam-se Sistemas Gerenciadores de Banco de Dados (SGBD). Elmasri e Navathe (2011) explicam que o papel do SGBD vai além do armazenamento, abrangendo a definição de regras de integridade, controle de concorrência e mecanismos de segurança contra perda de informação. No projeto em tela, a arquitetura de dados pode exigir uma abordagem híbrida: o uso de bancos de dados relacionais (SQL) para assegurar a consistência de registros transacionais e logs de produção, e soluções não-relacionais (NoSQL) para lidar com a natureza semiestruturada dos metadados gerados pela inferência dos tensores, proporcionando a flexibilidade necessária para consultas complexas e análise de grandes volumes de dados (Big Data).

3 REVISÃO DA LITERATURA

A modernização da indústria pesqueira tem sido objeto de diversos estudos que buscam alinhar o setor aos preceitos da Indústria 4.0. Esta revisão da literatura agrupa as pesquisas recentes em duas vertentes principais: a aplicação de algoritmos de visão computacional para análise de pescado e o desenvolvimento de arquiteturas de sistemas baseadas em IoT e computação em nuvem.

3.1 Análise e Classificação com Inteligência Artificial

A literatura acadêmica demonstra um avanço significativo no uso de redes neurais convolucionais para a automação da inspeção de pescados. Taheri-Garavand *et al.* (2019) propuseram um sistema de visão inteligente focado na avaliação do frescor de peixes, demonstrando que o uso de técnicas de *Deep Learning* supera os métodos tradicionais que dependiam da extração manual de características. Esse avanço é corroborado por Knausgård *et al.* (2022), que desenvolveram classificadores baseados em arquiteturas ResNet e VGG para a identificação de espécies e estimativa automática de peso em linhas de produção. O estudo desses autores enfatiza que o pré-processamento rigoroso dos tensores de entrada é crucial para mitigar ruídos visuais típicos de câmeras industriais, garantindo a precisão necessária em ambientes de alta rotatividade.

3.2 Rastreamento e Arquitetura de Sistemas

Além da classificação visual, o rastreamento eficiente dos ativos dentro da fábrica é uma preocupação central nas arquiteturas de IoT contemporâneas. Alfian *et al.* (2017) investigaram sistemas de rastreabilidade para cadeias de suprimentos de alimentos perecíveis, evidenciando que a integração de tecnologias sem fio (Wi-Fi/RFID) com protocolos de comunicação leves garante a integridade dos dados desde o ponto de captura até o armazenamento final em nuvem.

Em uma abordagem mais voltada à eficiência de rede, Ballas (2020) discute a implementação de *Edge Computing* (Computação de Borda) em linhas de montagem. O autor defende que o processamento inicial da IA - especificamente a inferência sobre os tensores - deve ser realizado próximo ao dispositivo de captura. Dessa forma, apenas os metadados resultantes da classificação são enviados via requisições HTTP para a nuvem, otimizando significativamente a largura de banda da rede industrial e reduzindo o tempo de resposta do sistema global.

4. METODOLOGIA

Esta seção fundamenta os procedimentos técnicos, as escolhas de engenharia e as estratégias operacionais que alicerçam o desenvolvimento do sistema proposto. Através de uma abordagem integrada que une visão computacional e computação de borda (*Edge Computing*), a metodologia descreve a transição de um processo tradicional de inspeção para um modelo automatizado, inteligente e rastreável. A seguir, detalham-se os pilares estruturais que compõem a arquitetura do sistema, elucidando a lógica de integração entre os componentes físicos e as camadas de software aplicadas ao rigoroso contexto da planta industrial.

4.1. Arquitetura e Fluxo de Operação do Sistema

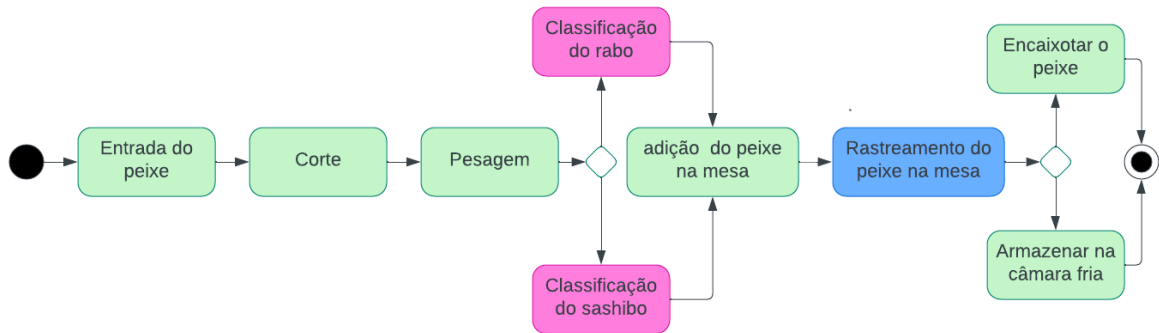


Figura 1 - Sistema geral do peixe

A solução proposta foi meticulosamente estruturada para integrar-se de forma orgânica à linha de produção de atum, harmonizando o hardware de captura de imagem com unidades de processamento de alto desempenho e sistemas de armazenamento em nuvem. Como ilustrado na Figura 1, o fluxo operacional do sistema espelha a sequência lógica da planta industrial, iniciando na entrada do peixe e avançando sistematicamente pelas etapas de corte e pesagem. Os processos do diagrama destacados nas cores rosa e azul são os processos que contém intervenção tecnológica por parte desse projeto, sendo o representado na cor rosa o processo de classificação e o em azul o processo de rastreamento.

É imediatamente após a pesagem que o sistema aciona seu primeiro estágio crítico de inteligência: o Módulo de Classificação de Qualidade (representados pela cor rosa no diagrama). Neste ponto, o fluxo se divide para realizar as análises simultâneas do rabo e do *sashibo*, visando determinar a qualidade intrínseca do produto. Para viabilizar esta etapa, utiliza-se o subsistema de captura denominado Câmera A, um sensor de ultra-alta resolução (4K). A escolha por esta especificação justifica-se pela necessidade de capturar detalhes minuciosos das fibras musculares e da coloração, transformando a imagem em tensores de alta dimensionalidade, representados matematicamente por $T \in \mathbb{R}^{H \times W \times C}$. Dada a complexidade computacional para processar tais dados e realizar inferências em redes neurais profundas, o sistema utiliza *Edge Computing* para garantir que a análise ocorra sem gerar gargalos na produção.

Dando continuidade ao percurso visualizado no diagrama, após a classificação, ocorre a adição do peixe na mesa, momento em que entra em operação o Módulo de Rastreamento. Este segundo estágio é monitorado pela Câmera B, que prioriza um alto campo de visão (*High*

Field of View - FOV) em detrimento da resolução extrema. O objetivo primordial nesta fase é a cobertura total da área de manipulação para evitar oclusões, permitindo que os algoritmos de visão computacional monitorem a trajetória de múltiplos atuns simultaneamente. Conforme indicado na transição final da Figura 1, este rastreamento contínuo é o que assegura que o nível de qualidade atribuído anteriormente permaneça vinculado ao peixe até o seu destino final, seja ele o encaixotamento ou o armazenamento na câmara fria.

Sob a ótica do desenvolvimento de software, a arquitetura prevê uma transição fluida entre dois modos de operação. Inicialmente, o sistema atua em uma fase de aquisição e treinamento *offline*, na qual as imagens brutas são coletadas e rotuladas por especialistas para o ajuste dos pesos das redes neurais. Uma vez maturados os modelos, o sistema transita para a fase de inferência e produção *online*. Neste estágio, o processamento ocorre em tempo real: a imagem adquirida é pré-processada, convertida em tensores e submetida à IA, que gera metadados contendo a classe e a posição do produto.

Finalmente, para garantir a persistência e a rastreabilidade histórica, esses resultados são encapsulados em pacotes de dados no formato JSON e transmitidos via protocolo HTTP através da rede Wi-Fi industrial. Este fluxo de comunicação conecta a inteligência de borda ao ambiente de nuvem, onde os dados são devidamente armazenados em bancos de dados estruturados, permitindo auditorias e consultas futuras sobre a qualidade de cada lote processado.

4.2. Infraestrutura de Hardware

A configuração da infraestrutura física do projeto foi meticulosamente selecionada para equilibrar o desempenho computacional na borda (*Edge Computing*) com a alta fidelidade na aquisição de dados, fator determinante para a eficácia de modelos de Inteligência Artificial. No centro dessa arquitetura, como unidade de processamento local, utiliza-se o Raspberry Pi 5 equipado com 8 GB de memória RAM. A opção por este *Single Board Computer* (SBC) fundamenta-se em sua arquitetura superior, que oferece o aporte computacional necessário para o pré-processamento de imagens e conversão de tensores em tempo real, além de suportar a carga de memória exigida por modelos densos de redes neurais e gerenciar a comunicação via protocolo HTTP com baixa latência.

No que tange aos sensores ópticos, o sistema de captura foi segmentado para atender a requisitos distintos das fases de classificação e rastreamento. Para a análise de qualidade (carne do rabo e *sashibo*), empregou-se uma câmera de alta resolução (4K), cuja densidade de pixels é essencial para a extração de *features* detalhadas sobre texturas e fibras musculares.

Em contrapartida, para o monitoramento da mesa de manipulação, utiliza-se uma câmera de alto campo de visão (High FoV). Equipada com lentes *wide angle*, este dispositivo minimiza pontos cegos e garante a continuidade da trajetória do pescado em toda a área de trabalho.

Complementando o hardware, o controle de iluminação e ambiente foi endereçado através de uma estrutura de captura controlada. Esta solução integra uma caixa de isolamento físico para padronizar o fundo e mitigar interferências da iluminação industrial, além de um sistema de iluminação anelar (Ring Light). A luz difusa e uniforme proveniente do LED circular é vital para neutralizar sombras severas e reflexos especulares na superfície úmida do peixe, assegurando que os tensores de entrada mantenham a consistência fotométrica necessária para a robustez dos algoritmos.

4.3. Ecossistema de Software e Tecnologias

O desenvolvimento de software é sustentado por uma pilha tecnológica moderna e otimizada para visão computacional. A linguagem Python atua como o eixo central para a manipulação de tensores e lógica de IA, enquanto *scripts* em Bash automatizam rotinas operacionais no Raspberry Pi 5. No nível das bibliotecas, o OpenCV é utilizado para o processamento de imagens, operando em conjunto com o NumPy para operações vetoriais de alto desempenho. A detecção e o rastreamento na mesa de processamento são realizados através do *framework* Ultralytics YOLOv8, enquanto a recepção de metadados na nuvem é gerenciada pelo FastAPI.

O ambiente de desenvolvimento foi padronizado utilizando o VSCode integrado ao Git, garantindo reprodutibilidade via ambientes virtuais (*venv*). Para a fase de experimentação e treinamento de modelos de *Deep Learning*, utiliza-se o Google Colab, que provê o poder de processamento de GPUs necessário para o treinamento ágil. Por fim, a validação das interfaces de comunicação e das requisições HTTP entre os dispositivos de borda e o *backend* é realizada com o auxílio do Postman, assegurando a integridade do fluxo de dados antes da implementação definitiva.

4.4. Estratégias de Teste e Validação

Dadas as restrições de acesso ao ambiente fabril, o plano de testes foi adaptado para focar em Provas de Conceito (PoC) laboratoriais e no controle de qualidade dos dados coletados. A validação das comunicações concentra-se na integridade do protocolo HTTP, testando-se exaustivamente requisições POST para assegurar que os metadados das classificações cheguem ao *endpoint* da API sem perdas.

No âmbito da coleta de dados, os testes laboratoriais simularam as condições de iluminação controlada através da caixa de isolamento e do *ring light*, permitindo a padronização dos tensores visuais antes da aplicação em campo. Esse rigor estende-se à estruturação do *dataset*, que atualmente passa por um processo de verificação e rotulagem das 500 imagens iniciais. O objetivo é garantir que o banco de dados esteja perfeitamente alinhado aos formatos de entrada exigidos pelos modelos de aprendizado supervisionado, consolidando uma base sólida para as próximas etapas de treinamento abrangente.

5 RESULTADOS E DISCUSSÕES

Esta seção detalha o progresso técnico alcançado até o momento, destacando as adaptações metodológicas necessárias em função do *feedback* obtido no ambiente industrial e dos desafios logísticos inerentes ao projeto.

5.1. Aquisição, Curadoria e Preparação do Dataset

O processo de coleta de dados, pilar fundamental para o sucesso dos modelos de classificação, foi iniciado sob condições de restrições logísticas. Apesar desses desafios, consolidou-se um banco inicial composto por mais de 500 imagens de cortes de atum. Este volume, embora preliminar, permite o início das atividades de estruturação do *pipeline* de dados. Atualmente, o banco de imagens passa por um processo rigoroso de preparação e rotulagem para viabilizar o treinamento supervisionado. Essa etapa ocorre em ambiente de computação em nuvem via Google Colab, onde são empregadas bibliotecas de alto desempenho, como TensorFlow e PyTorch, para a manipulação eficiente de tensores de imagem e a aplicação de técnicas de pré-processamento.

5.2. Arquitetura de Comunicação e Prototipagem de Software

Paralelamente à gestão de dados, a arquitetura de software voltada à comunicação entre dispositivos encontra-se em fase avançada de prototipação. Foi desenvolvida e operacionalizada uma API de metadados fundamentada no *framework* FastAPI, escolhido por sua alta performance e facilidade de integração. Esta API atua como o núcleo receptor das informações, processando tanto os resultados das inferências de classificação quanto os dados de rastreabilidade, incluindo coordenadas de localização e registros temporais (*timestamps*), transmitidos via protocolo HTTP.

A viabilidade técnica desta infraestrutura foi validada por meio de testes de integração conduzidos no laboratório LAICA. Durante os experimentos, utilizou-se um Raspberry Pi 5 para simular o comportamento de um dispositivo de borda (*edge computing*), encapsulando resultados de classificação em pacotes JSON. O sucesso no envio desses dados para o *backend* em nuvem via Wi-Fi comprovou a robustez do fluxo de comunicação sem fio proposto, assegurando que a arquitetura suportará a carga operacional prevista.

5.3. Análise Crítica e Direcionamentos Estratégicos

O desenvolvimento parcial do projeto foi marcado por decisões operacionais que moldaram o rumo das atividades. É importante ressaltar que a restrição do tempo de permanência na planta industrial, somada à indisponibilidade de equipamentos específicos, limitou a diversidade e o volume estatístico do conjunto de imagens. Tal limitação impacta diretamente o potencial de generalização dos modelos, exigindo uma postura cautelosa quanto aos resultados preliminares. Embora as provas de conceito laboratoriais tenham sido essenciais para a validação de fluxos de trabalho, elas não substituem a necessidade de uma coleta massiva em ambiente de produção para garantir a robustez final do sistema.

Diante desse cenário, o planejamento estratégico para as próximas etapas prioriza a expansão sistemática da coleta de imagens em campo e a consolidação do processo de rotulagem. Além disso, o foco será direcionado à conclusão do aplicativo móvel - que servirá como ferramenta facilitadora na ponta da produção - e ao esforço contínuo para retomar as coletas com os equipamentos originais, visando reduzir a discrepância entre os testes controlados de laboratório e a realidade da planta industrial.

6 CONCLUSÃO

Este relatório detalha o estágio parcial do projeto, evidenciando avanços significativos na implementação das rotinas de captura e pré-processamento, além da realização de treinamentos preliminares via Google Colab. A viabilidade das abordagens escolhidas foi sustentada por provas de conceito conduzidas no laboratório LAICA e pela organização de um banco de dados inicial composto por cerca de 500 imagens obtidas em duas visitas à empresa. Como resposta direta ao feedback da organização, iniciou-se também o desenvolvimento de um aplicativo móvel dedicado à captura de dados.

Apesar do progresso, o projeto enfrenta limitações inerentes ao acesso restrito à planta

industrial e aos equipamentos específicos solicitados, o que resulta em um volume de dados ainda insuficiente para o treinamento definitivo dos modelos e na pendência de validações em ambiente real de produção.

Para as etapas subsequentes, priorizar-se-á a expansão da coleta de imagens em campo para diversificação do *dataset*, acompanhada da rotulagem rigorosa desses dados. Paralelamente, pretende-se concluir o desenvolvimento do aplicativo móvel para testes de usabilidade *in loco* e, se possível, retomar as coletas com o maquinário solicitado, permitindo uma comparação técnica robusta entre os resultados laboratoriais e o cenário industrial.

REFERÊNCIAS

ALFIAN, G. et al. IoT-based traceability system for perishable food supply chain. **IEEE Access**, v. 5, p. 23970-23979, 2017.

BALLAS, H. Artificial Intelligence and Edge Computing in the Food Industry. **Journal of Food Engineering**, v. 12, n. 4, p. 45-58, 2020.

ELMASRI, R.; NAVATHE, S. B. **Sistemas de banco de dados**. 6. ed. São Paulo: Pearson Addison Wesley, 2011.

FIELDING, R. et al. **Hypertext Transfer Protocol -- HTTP/1.1**. RFC 2616. IETF, 1999. Disponível em: <https://tools.ietf.org/html/rfc2616>. Acesso em: 10 out. 2023.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

KNAUSGÅRD, K. M. et al. Temperate fish species classification with deep convolutional neural networks. **Access, IEEE**, v. 10, p. 12345-12355, 2022.

MELL, P.; GRANCE, T. **The NIST Definition of Cloud Computing**. Gaithersburg: National Institute of Standards and Technology, 2011. (Special Publication 800-145).

RATHI, D. et al. A review on deep learning approaches for fish detection and classification. **Multimedia Tools and Applications**, v. 81, p. 1-36, 2022.

RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3. ed. Upper Saddle River: Pearson, 2013.

TAHERI-GARAVAND, A. et al. A real-time computer vision system for automated inspection of fish freshness. **Journal of Food Engineering**, v. 247, p. 140-149, 2019.

TANENBAUM, A. S.; WETHERALL, D. J. **Redes de Computadores**. 5. ed. São Paulo: Pearson Prentice Hall, 2011.