

Sistema Inteligente para Monitoramento de Conversão de Vendas no Varejo Físico com Visão Computacional, IoT e Integração a Plataforma PDV

Bruna Gonçalves Ribeiro
UniSenac
Pelotas, Brasil
bruna.bgribeiro@gmail.com

Gladimir Ceroni Catarino
UniSenac
Pelotas, Brasil
gladimir@gmail.com

Pablo de Chiaro Rosa
UniSenac
Pelotas, Brasil
pablo.chiaro.rosa@gmail.com

Vinicius Dobke
UniSenac
Pelotas, Brasil
vinicius.d.gaspar@gmail.com

Karolaine Maia
UniSenac
Pelotas, Brasil
karolaineprinzmaia@gmail.com

Natália Brandão
UniSenac
Pelotas, Brasil
nataliabrandao688@gmail.com

Abstract— This project presents the development of an intelligent system for monitoring sales conversion rates in physical retail. The solution employs computer vision, based on YOLOv6/v11n models, for the automatic counting of customer entries, integrating this data with Point of Sale (POS) systems to correlate flow with sales transactions. To enhance accuracy, an IoT module with RFID technology is proposed to identify and filter non-customer entries, such as employees and companions. This article details the project's initial results, covering the validation of the computer vision models in simulated environments and the architectural design of the IoT tracking system. The complete system aims to provide strategic insights for retailers, optimizing decision-making and operational efficiency.

Keywords—Computer Vision, IoT, Sales Conversion, Physical Retail, YOLO, RFID

Resumo— Este projeto apresenta o desenvolvimento de um sistema inteligente para monitoramento da taxa de conversão de vendas no varejo físico. A solução emprega visão computacional, baseada nos modelos YOLOv6/v11n, para a contagem automática da entrada de clientes, integrando esses dados aos sistemas de Ponto de Venda (PDV) para correlacionar o fluxo com as transações de vendas. Para aumentar a precisão, é proposto um módulo de IoT com tecnologia RFID para identificar e filtrar entradas de não-clientes, como funcionários e acompanhantes. Este artigo detalha os resultados iniciais do projeto, abordando a validação dos modelos de visão computacional em ambientes simulados e o design arquitetônico do sistema de rastreamento IoT. O sistema completo visa fornecer insights estratégicos para o varejista, otimizando a tomada de decisão e a eficiência operacional.

Palavras-chave—Visão Computacional, IoT, Conversão de Vendas, Varejo Físico, YOLO, RFID.

I. INTRODUÇÃO

O setor varejista enfrenta desafios crescentes relacionados à eficiência operacional, à gestão inteligente de recursos e à sustentabilidade de seus processos [1]. Um dos principais obstáculos é a falta de ferramentas precisas para monitoramento do fluxo de clientes e sua correlação direta com os dados de vendas, o que dificulta a alocação estratégica de recursos humanos e materiais. Essa limitação pode resultar em desperdícios operacionais, redução da competitividade e perda de oportunidades de venda.

Nesse cenário, a adoção de tecnologias emergentes, como a visão computacional e a Internet das Coisas (IoT), surge como uma alternativa promissora para transformar a gestão no varejo físico. Ao viabilizar o reconhecimento automatizado de entradas de clientes e o cruzamento inteligente com dados transacionais, essas soluções fornecem compreensões estratégicas, otimizando a tomada de decisão e o desempenho do ponto de venda [2].

Além da melhoria na eficiência operacional, a integração entre sistemas de visão computacional e plataformas de gestão de vendas permite uma análise mais aprofundada do comportamento do consumidor. Isso possibilita a personalização de serviços, a qualificação do atendimento e o aprimoramento da experiência do cliente [3]. Consequentemente, tais práticas não apenas aumentam a produtividade e o retorno sobre investimento, mas também promovem a sustentabilidade do comércio ao reduzir desperdícios e otimizar o uso de recursos [4].

Este artigo apresenta os primeiros resultados de um

sistema inteligente para monitoramento da conversão de vendas no varejo físico, baseado em visão computacional, IoT e integração com plataformas de ponto de venda (PDV). A proposta visa contribuir com soluções livres e replicáveis para o setor, com foco em acessibilidade tecnológica e inovação aberta.

II. METODOLOGIA

A metodologia deste projeto foi estruturada em duas frentes complementares: a condução técnico-científica realizada pelos docentes pesquisadores — responsáveis pelo planejamento, acompanhamento e validação dos resultados — e a atuação de dois discentes de graduação, que executam a implementação prática do sistema, promovendo a integração entre teoria acadêmica e inovação tecnológica. A abordagem adotada é exploratório-aplicada, com métodos qualitativos e quantitativos, empregando técnicas de engenharia de software, aprendizado de máquina e visão computacional. A solução desenvolvida visa integrar modelos de detecção de pessoas (YOLOv6/v11n) com dados de vendas oriundos da plataforma PDV, permitindo a correlação entre fluxo de clientes e conversão de vendas no varejo físico [5]. O desenvolvimento é organizado em quatro fases iterativas. A primeira fase aborda planejamento e levantamento de requisitos, incluindo estudo do estado da arte, definição tecnológica e análise de sistemas similares. Em seguida, a segunda fase executa a prototipação e define a arquitetura de software, com destaque para modelagem de casos de uso e inicialização do repositório GitLab. A terceira fase visa a construção do Mínimo Produto Viável (MVP), incorporando reconhecimento de entrada, integração via arquivos CSV e lógica para exclusão de funcionários e acompanhantes por meio de dispositivos IoT. Finalmente, a quarta fase objetiva testes em ambiente real, envolvendo a coleta de dados de uma loja piloto, a validação da acurácia do sistema e a análise do impacto nas operações de venda, além de incorporar o feedback qualitativo de usuários finais como gerentes e vendedores.

A arquitetura deste projeto foi concebida sob princípios de reprodutibilidade e abertura, utilizando exclusivamente tecnologias abertas (como YOLO, Arduino e MQTT) e padrões documentados publicamente. Todo o design — incluindo fluxos de processamento, protocolos de integração e critérios de validação — é replicável por terceiros sem dependência de componentes proprietários. Essa abordagem garante que a solução possa ser reconstruída ou adaptada livremente pela comunidade, alinhando-se aos objetivos de democratização tecnológica do software livre e hardware aberto.

III. RESULTADOS E DISCUSSÕES

Os primeiros experimentos conduzidos no escopo do projeto resultaram na construção de modelos de aprendizado de máquina baseados em redes neurais convolucionais, com foco na detecção de pessoas em ambientes de varejo físico. A escolha inicial do modelo *You Only Look Once version 6* (YOLOv6), desenvolvido pela Meituan, foi fundamentada em uma revisão bibliográfica sistemática e em testes comparativos preliminares [6]. O YOLOv6 demonstrou desempenho superior frente a outras variantes populares, destacando-se tanto em acurácia quanto em velocidade de inferência. Como parte da evolução técnica, o projeto passou

a incluir experimentos com o YOLOv11 e incorporou práticas alinhadas à LGPD, priorizando a anonimização das imagens e a coleta de metadados agregados. Além disso, todos os participantes do ambiente de teste assinaram termos de consentimento, reforçando o compromisso com transparência e ética na pesquisa.

A uso do YOLOv6 considerou os dados apresentados no estudo, que demonstram que, em ambiente TensorRT FP16 com GPU Tesla T4, o modelo YOLOv6-N atinge 37,5% de *Average Precision* (AP) com 1.187 FPS em lotes de 32 imagens, enquanto o YOLOv6-S alcança 45% de AP com desempenho de 484 FPS. Além dos resultados quantitativos, a decisão pela arquitetura também levou em conta inovações estruturais como a *Path Aggregation Network* com *Replication and Bidirectional Concatenation*, o mecanismo *Anchor-Aided Training* e a técnica de *self-distillation*, que juntos contribuem para um equilíbrio eficiente entre precisão e baixa latência, preservando detalhes espaciais essenciais para aplicações sensíveis ao tempo.

Durante esta etapa da pesquisa, foram desenvolvidos modelos experimentais iniciais, nomeados RIVAC-CV-1, RI *Retail Intelligence* (RI) e *Vision and Analytics* (VA), com variações de configuração voltadas à otimização da detecção de pessoas [7]. Os experimentos foram conduzidos em ambientes simulados, incluindo testes com diferentes resoluções de entrada, cenários com variações de iluminação e densidade de pessoas, aspectos críticos para replicação em ambientes reais de loja. Paralelamente, iniciou-se a experimentação com o modelo YOLOv11, que representa uma evolução arquitetural significativa do YOLOv6 validado, incorporando melhorias e otimizações no processo de treinamento que prometem maior eficiência sem comprometer a acurácia. Os resultados preliminares indicaram que o modelo atende os requisitos do projeto, destacando a capacidade de detectar a classe "pessoa" do modelo YOLO, garantia do *region of interest* (ROI) para contagem de entradas/saída conforme ilustra a Figura 1, enquanto os testes iniciais com YOLOv11 sugerem potencial de melhoria na relação precisão-velocidade.



Fig 1. Processamento RIVAC-CV-1 ambiente simulado

A performance do modelo foi avaliada também sob o aspecto de latência de inferência. Com base nos tempos apresentados no estudo de referência (1–3 ms por imagem em lote unitário), o YOLO demonstrou que a aplicação atinge latência inferior a 5 ms, fator decisivo para garantir a operação sem atrasos perceptíveis na coleta de dados. Os experimentos preliminares com YOLOv11 indicam potencial de redução

adicional da latência, com estimativas iniciais sugerindo melhorias de 15-20% na velocidade de inferência devido às otimizações arquiteturais implementadas na versão 11. A evolução para o modelo YOLOv11 oferece vantagem competitiva em cenários de alta demanda, permitindo monitorar entradas de clientes e calcular a taxa de conversão integrada ao PDV. Sua licença AGPL-3.0 autoriza uso comercial, modificação e distribuição, desde que o código-fonte das alterações também seja disponibilizado sob a mesma licença.

Em síntese, os experimentos realizados até o momento validam a viabilidade técnica do uso do YOLO como núcleo do *pipeline* de visão computacional proposto. Os resultados confirmam que a arquitetura atende aos requisitos de acurácia, rapidez e robustez, servindo como base sólida para integrar IoT e plataformas de venda, alinhando-se a sistemas automáticos de *checkout* já descritos na literatura [8].

No contexto da arquitetura de rastreamento RIVAC-IoT-1, foi iniciado o desenvolvimento de um modelo lógico voltado à identificação automatizada de objetos por meio de tecnologia RFID, ilustrada na Figura 2, visando a integração eficiente com o sistema de visão computacional proposto. A solução emprega etiquetas RFID passivas compatíveis com o padrão ISO/IEC 14443A, lidas por módulos RC522 e PN532 operando na frequência de 13,56 MHz. Para os testes iniciais, optou-se por microcontroladores amplamente acessíveis e versáteis, Arduino UNO R3 e ESP32-C3, explorando tanto a comunicação serial quanto o envio de dados via protocolo MQTT para simular a integração com sistemas externos, como *dashboards* ou plataformas de controle.



Fig 2. Tecnologia RFID

Os experimentos preliminares estão sendo realizados em ambientes virtuais de simulação, com destaque para as plataformas Wokwi e TinkerCAD Circuits, que oferecem suporte à prototipação de circuitos com recursos como displays (LCD 16x2 e OLED), sensores e barramentos (I2C, SPI e UART). Nesses simuladores, estão sendo avaliadas as operações de leitura de tags, os tempos médios de resposta do leitor RFID, bem como a visualização de informações por meio de interfaces simuladas e feedbacks visuais e sonoros com LEDs e buzzers. A fase atual também contempla a codificação dos UID das etiquetas, o mapeamento de ações conforme o tipo de tag detectado (ex: identificação de funcionários ou acompanhantes) e a definição de uma lógica de filtragem de eventos, essencial para garantir a precisão no cálculo da taxa de conversão no ponto de venda.

A estratégia adotada segue uma abordagem escalonada de desenvolvimento, partindo da simulação virtual para posterior

migração ao protótipo físico, o que permite maior controle sobre o comportamento do sistema e a antecipação de falhas ou gargalos. Tal abordagem não apenas maximiza o aprendizado técnico da equipe envolvida, como também fortalece a viabilidade de integração entre o módulo de rastreamento RFID e o *pipeline* de visão computacional baseado em YOLO. Os testes em simuladores visam fornecer dados importantes sobre a robustez da leitura de tags em diferentes distâncias e orientações, o que será essencial para o ajuste fino do sistema no ambiente físico.

Esses avanços indicam que o módulo RIVAC-IoT-1 apresenta potencial significativo para ser incorporado como camada complementar de rastreamento inteligente na arquitetura geral do sistema. A combinação entre rastreamento por RFID e análise por visão computacional abre caminho para maior acurácia na exclusão de entradas irrelevantes (como acompanhantes ou funcionários), otimizando o cálculo da taxa de conversão em ambientes de varejo físico.

IV. CONCLUSÃO

Este projeto tem como objetivo o desenvolvimento e implementação de um sistema inteligente de monitoramento de conversão de vendas no varejo físico, através do uso de visão computacional para realizar o reconhecimento automático da entrada de clientes em estabelecimentos comerciais. Em fases subsequentes este projeto será integrado com IoT como *guard-rail* para garantir maior exatidão das informações obtidas.

Juntamente da implementação do sistema desenvolvido, este projeto também realizará o estudo do impacto dessa tecnologia no setor do comércio, além de validar os modelos usados no contexto comercial e discriminar maneiras de superar ou contornar quaisquer adversidades encontradas [9].

Concluímos, portanto, que este projeto é de suma importância para o setor comercial pois, através de compreensões estratégicas fornecidas por Visão Computacional e IoT, ele melhorará não só a eficiência operacional, otimizando a tomada de decisões e o desempenho do ponto de venda, bem como permitirá uma análise mais aprofundada do comportamento do consumidor, possibilitando uma melhor experiência do cliente, por meio de personalização de serviços e qualificação do atendimento [10].

Além de ser relevante para o setor da tecnologia, uma vez que as características identificadas por este projeto podem impulsionar não só o descobrimento e popularização de tecnologias aptas para o nicho do projeto, juntamente do eventual desenvolvimento de novas tecnologias úteis não só para o setor comercial, da mesma forma para os demais setores.

AGRADECIMENTOS

Ao Centro Universitário Senac RS, à Reitoria, pró Reitoria de Pesquisa e Coordenações.

REFERÊNCIAS

- [1] M. Adžemović, “Deep learning-based multi-object tracking: a comprehensive survey from foundations to state-of-the-art,” 2025. Disponível em:

- <https://arxiv.org/abs/2506.13457>. [acesso em maio 2025]. [10]
- [2] G. H. A. D. Carvalho, e. M. V. Junior e f. A. Nascimento, “Vigilância inteligente em lojas com visão computacional e inteligência artificial,” 2025. Disponível em: <https://revistaft.com.br/vigilancia-inteligente-em-lojas-com-visao-computacional-e-inteligencia-artificial/>. [acesso em julho 2025].
- [3] V. B. Ayoola, g. Osam-nunoo e c. Umeaku, “IoT-driven smart warehouses with computer vision for enhancing inventory accuracy and reducing discrepancies in automated systems,” 2024. Disponível em: https://www.researchgate.net/publication/386110610_iot-driven_smart_warehouses_with_computer_vision_for_enhancing_inventory_accuracy_and_reducing_discrepancies_in_automated_systems. [acesso em junho 2025].
- [4] S. Rukundo, d. Wang, f. Wongnonthawitthaya, sidibé, youssouf, kim, minsik, s. Emily e z. Jiale, “A survey of challenges and sensing technologies in autonomous retail systems,” 2025. Disponível em: <https://arxiv.org/abs/2503.07997>. [acesso em junho 2025].
- [5] A. Hossam, a. Ramadan, m. Magdy, r. Abdelwahab, s. Ashraf e z. Mohamed, “Revolutionizing retail analytics: advancing inventory and customer insight with ai,” 2024. Disponível em: <https://arxiv.org/abs/2405.00023>. [acesso em junho 2025].
- [6] L. Tan, s. Liu, j. Gao, x. Liu, l. Chu e h. Jiang, “Enhanced self-checkout system for retail based on improved YOLOv10,” 2024. Disponível em: <https://arxiv.org/abs/2407.21308>. [acesso em junho 2025].
- [7] K. R. Kanjula, v. V. Reddy, j. K. P, j. S. Abraham e t. K, “People counting system for retail analytics using edge ai,” 2022. [online]. Disponível em: <https://arxiv.org/abs/2205.13020>. [acesso em junho 2025].
- [8] A. W. A. Syed talha bukhari, m. A. Naveed e m. R. Abbas, “Arc: a vision-based automatic retail checkout system,” 2021. Disponível em: <https://arxiv.org/abs/2104.02832>. [acesso em junho 2025].
- [9] K. R. Štofková, f. Bajza, p. Janošková e m. Kováčiková, “Proposal of innovative smart solutions for retail store in order to support competitiveness and sustainable development,” 2024. Disponível em: <https://www.frontiersin.org/journals/computer-science/articles/10.3389/fcomp.2024.1328913/full>. [acesso em junho 2025].
- S. Patel, “Role of computer vision in retail stores,” 2024. [online]. Disponível em: https://www.researchgate.net/publication/385777137_role_of_computer_vision_in_retail_stores. [acesso em junho 2025].