

EduScore: Correção Automática de Cartões-Resposta por Deep Learning e Visão Computacional

Matheus dos Anjos Pinheiro¹, Osvaldo Tavares Viana Junior¹

¹ Universidade do Estado do Amazonas (UEA)

Av. Darcy Vargas, 1200 – Manaus – AM – Brasil

{mdap.lic20, ojuniior}@uea.edu.br

Abstract. *A manual for correcting mock exams for university entrance exams like the ENEM is time-consuming and prone to errors, requiring feedback to students. This article presents EduScore, a platform that automates the recognition and correction of physical answer sheets from images captured by smartphone. In the initial development phase, the system already integrates a detection pipeline based on YOLO and SAM2. Preliminary results indicate high accuracy in locating regions of interest (mAP@50 of 91% in real tests). Next steps include full validation of the OMR module, expansion of the dataset, and user testing in a real-world environment.*

Resumo. *A correção manual de simulados para vestibulares como o ENEM é demorada e sujeita a erros, comprometendo o feedback aos alunos. Este artigo apresenta o EduScore, uma plataforma que automatiza o reconhecimento e a correção de cartões-resposta físicos a partir de imagens capturadas por smartphone. Em estágio inicial de desenvolvimento, o sistema já integra um pipeline de detecção baseado em YOLO e SAM2. Resultados preliminares indicam alta precisão na localização das regiões de interesse (mAP@50 de 91% em testes reais), como próximos passos, planeja-se a validação completa do módulo OMR, a expansão do dataset e testes com usuários em ambiente real.*

1. Introdução

No Brasil, exames de admissão como o Exame Nacional do Ensino Médio (ENEM) e vestibulares regionais utilizam cartões-resposta físicos padronizados como principal meio de registro das respostas. Apesar da digitalização de diversos processos educacionais, a correção de simulados e provas em contextos de preparação ainda depende de procedimentos manuais ou de sistemas pouco flexíveis, sujeitos a falhas que comprometem a precisão dos resultados. Casos recentes envolvendo inconsistências na correção de exames em larga escala evidenciam os desafios relacionados ao processamento confiável de folhas-resposta e gabaritos. No ENEM 2019, erros de associação entre cadernos de prova e gabaritos afetaram milhares de candidatos durante a correção automatizada [UOL Educação 2020, ISTOÉ 2020]. Tais ocorrências reforçam a necessidade de soluções mais confiáveis, automatizadas e auditáveis para a correção de avaliações objetivas.

A ampla disseminação de *smartphones* com câmeras de alta resolução tem impulsionado o uso desses dispositivos como alternativa acessível e portátil para digitalização e processamento de documentos, especialmente em cenários que demandam mobilidade e

baixo custo computacional [Bernardino et al. 2023, Wigington 2024]. Essa abordagem permite que a digitalização de cartões-resposta ocorra em sala de aula ou em ambientes não controlados, sem a necessidade de equipamentos específicos como scanners dedicados [Oliveira et al. 2020]. Por outro lado, computadores atuam como receptores e processadores dessas imagens, executando algoritmos robustos de visão computacional e aprendizado de máquina baseados em redes neurais convolucionais profundas [Szeliski 2010, Krizhevsky et al. 2012]. A vantagem do celular reside, portanto, na portabilidade da captura, enquanto o computador assume a etapa de processamento e análise, sem a função de aquisição direta [Redmon et al. 2016]

O *EduScore* é uma plataforma que automatiza o reconhecimento e a correção de cartões-resposta do ENEM a partir de imagens capturadas por dispositivos móveis ou computadores. A solução integra técnicas de visão computacional e aprendizado de máquina para geração de notas, relatórios e análises de desempenho, destacando-se pela acessibilidade da captura via *smartphone* e pelo processamento sem necessidade de infraestrutura dedicada. Este trabalho concentra-se inicialmente no ENEM como prova de conceito, dado seu alcance nacional e alto grau de padronização, com extensão planejada para outros formatos como trabalho futuro. A proposta fundamenta-se no *Technology Acceptance Models* (TAM) [Davis 1989] e em princípios de *User Experience* (UX) [Garrett 2010], visando não apenas a funcionalidade, mas também a adoção efetiva pelos *stakeholders*.

2. Trabalhos Relacionados

[Rangel 2021] propõe um sistema automático de correção de folhas de respostas objetivas baseado em processamento de imagens, capaz de reconhecer *QR Codes* e marcações em cartões-resposta. Embora alcance alta precisão na leitura e correção, a solução limita-se à etapa de correção, não explorando o potencial analítico dos dados coletados nem avançando para análises preditivas ou integração com modelos de aprendizado de máquina. [Fileno et al. 2025] propõem um sistema automatizado para criação e correção de provas de múltipla escolha com embaralhamento inteligente de gabaritos. A solução utiliza processamento de imagem e leitura de *QR Code* para realizar a correção automática, tendo sido validada no Colégio Técnico Antônio Teixeira Fernandes, comprovando sua eficiência superior em relação a métodos tradicionais. Embora o sistema compartilhe com o *EduScore* o objetivo de automatizar a correção por meio de processamento de imagens, sua abordagem concentra-se no embaralhamento de gabaritos para segurança da avaliação, sem incorporar técnicas de aprendizado de máquina para detecção adaptativa de diferentes layouts de cartões-resposta.

[Oliveira and Silva 2024] propõem o Avalia, sistema de correção de respostas dissertativas utilizando *Optical Character Recognition* (OCR) e Inteligência Artificial (IA) para *feedback* automático. Em contraste com o *EduScore*, focado em detecção de *layouts* e leitura de cartões-resposta, ambos são complementares no contexto educacional. No âmbito internacional, sistemas *Optical Mark Recognition* (OMR) baseados em visão computacional têm avançado tanto em precisão quanto em flexibilidade: [Mondal et al. 2024] propõem o OMRNet, modelo leve em (CNN) *Convolutional Neural Network* capaz de classificar marcações em três categorias (marcada, vazia e rasurada), enquanto [Rajagopal and Saha 2024] demonstram correção automática via câmera

com OpenCV (*Open Source Computer Vision Library*) atingindo 99,76% de acurácia em exames reais. Contudo, ambas as abordagens pressupõem templates fixos e condições controladas de captura, limitação que o *EduScore* busca superar por meio da detecção adaptativa de layout. [Abreu et al. 2025] explora o treinamento de um detector de gabaritos utilizando *Roboflow* e *Google Colab*, concentrando-se especificamente na etapa de treinamento e validação de um modelo de detecção de objetos. Embora demonstre a viabilidade técnica da abordagem, o trabalho permanece no âmbito experimental, sem integrar o modelo a uma plataforma educacional completa que contemple correção, análise e visualização de resultados.

Os trabalhos analisados abordam etapas específicas da correção automatizada, mas não integram todo o processo em uma solução unificada e acessível. O diferencial do *EduScore* está justamente na integração entre captura móvel, detecção automática do cartão-resposta, correção, geração de relatórios e análises de desempenho em uma única plataforma, sem exigir infraestrutura especializada e com potencial de adaptação a diferentes contextos educacionais.

2.1. Análise Comparativa e Posicionamento do EduScore

A Tabela 1 apresenta um *benchmarking* detalhado entre as soluções existentes e o *EduScore*, destacando os diferenciais competitivos da plataforma proposta. Essa comparação foi fundamentada tanto na revisão de literatura e documentação oficial das ferramentas quanto nas percepções relatadas pelos profissionais entrevistados.

Tabela 1. Benchmark comparativo simplificado						
Solução	1	2	3	4	5	6
EduScore	Sim	Sim	Não	Sim	Alto	Alto
KaptureAll	Não	Parcial	Sim	Sim	Médio	Limitada
Remark OMR	Não	Parcial	Sim	Sim	Médio	Limitada
Evolucional	Não	Não	Sim	Sim	Alto	Baixo
Examica	Não	Sim	Sim	Sim	Alto	Médio
Acadêmicos (YOLO/CNN)	Sim	Parcial	Não	Limitada	Médio	Médio

¹Detecção automática das regiões do cartão. ²Suporte a captura móvel.
³Scanner dedicado necessário. ⁴Relatórios e análises. ⁵Facilidade de uso. ⁶Adaptação a diferentes layouts.

Plataformas comerciais como Evolucional e Examica oferecem análises descritivas de desempenho e relatórios, porém dependem de configurações prévias e não fornecem detecção automática do tipo de cartão-resposta a partir de imagens capturadas em condições variáveis. Em contraste com as soluções existentes, o *EduScore* posiciona-se como uma plataforma integrada que combina a portabilidade da captura por dispositivos móveis com um pipeline robusto de visão computacional e aprendizado de máquina.

A proposta avança além da correção automatizada, ao incorporar a detecção adaptativa de *layouts* por meio de modelos de visão computacional, como YOLO (*You Only Look Once*) [Redmon et al. 2016] e SAM2 [Ravi et al. 2024]. O reconhecimento óptico

de caracteres (OCR) [Smith 2007] para identificação contextual do dia de aplicação da prova, e a geração de análises de desempenho, abordagem que visa suprir a lacuna de sistemas acessíveis e integrados identificada na literatura.

3. Estrutura do Sistema

A plataforma *EduScore* segue um fluxo modular e sequencial, desde a captura da imagem até a geração de relatórios. A Figura 1 apresenta a interface de upload na versão desktop, na qual o usuário pode enviar a imagem do cartão-resposta capturada por *smartphone* ou já armazenada no computador. Após o envio, o sistema realiza um pré-processamento básico, como validação do formato e redimensionamento, antes de encaminhar a imagem ao pipeline de detecção. No primeiro estágio do pipeline, o YOLOv8s atua como detector primário, localizando a folha A4 na imagem mesmo sob condições desafiadoras de iluminação, rotação ou fundo, e produzindo uma *bounding box* que delimita sua região aproximada. Essa caixa delimitadora é então utilizada como prompt pelo *Segment Anything Model 2* (SAM2) [Ravi et al. 2024], um modelo de segmentação zero-shot [Wang et al. 2019] de código aberto, que gera uma máscara binária pixel a pixel, isolando com precisão a folha do fundo, conforme ilustrado na Figura 2.

Com a máscara gerada, o sistema aplica uma transformada de perspectiva para retificar a imagem, corrigindo distorções causadas por ângulos de captura não ortogonais. A implementação da Transformada de Hough adotada neste trabalho difere da abordagem clássica descrita por [Junior 2014]: enquanto a teoria tradicional propõe uma etapa distinta de binarização via detector de bordas Canny para gerar um mapa binário como entrada da transformada, o algoritmo desenvolvido, implementado no método *houghTransform*, itera diretamente sobre a matriz de gradientes, condicionando a votação à intensidade do gradiente de cada pixel por meio de um limiar dinâmico. Essa abordagem elimina a criação de uma matriz intermediária de bordas, reduzindo consumo de memória e processamento sem comprometer a precisão na detecção das retas. O resultado é a folha retificada, apresentada na figura ¹ que pode ser visualizada no link disponível, recortada com uma margem de 7% em relação às bordas detectadas para preservar todo o conteúdo relevante e minimizar interferências do fundo.

A imagem retificada é então submetida ao YOLOv11s, conforme apresentado na imagem ² disponível para acesso, treinado especificamente para detectar as regiões de interesse na folha de resposta do ENEM: *answer_area_enem* (área das 90 questões) e *day_region* (campo de identificação do dia). Ao operar em um espaço visual padronizado, o modelo torna-se robusto a variações geométricas, garantindo a correta localização dos campos críticos, cujas ROIs extraídas são visualizadas na figura ³.

Region of Interest (ROI) *day_region* é processada por um módulo OCR baseado na biblioteca *Tesseract*, atualmente em fase inicial de desenvolvimento, que classifica o cartão como “Dia 1” ou “Dia 2”. Essa identificação é crítica para a lógica de correção, pois determina o deslocamento posicional do gabarito de referência: o primeiro


¹Disponível em: https://anonymous.4open.science/r/SBIE-75C6/transf_persc_2_enem.png

²Disponível em: <https://anonymous.4open.science/r/SBIE-75C6/detecµes.png>

³Disponível em: https://anonymous.4open.science/r/SBIE-75C6/crop_enem.jpeg


dia abrange as questões de 1 a 90, enquanto o segundo dia mapeia as respostas para o intervalo de 91 a 180. Por fim, a ROI `answer_area_enem` é submetida a um algoritmo de Leitura Óptica de Marcações (OMR) desenvolvido com OpenCV, também em estágio preliminar de ajustes e refinamento, que aplica limiarização global, detecta os círculos de resposta e contabiliza os pixels preenchidos em cada região para determinar a alternativa assinalada pelo aluno. A tabela ⁴ disponível para consulta resume os principais módulos da plataforma, suas funcionalidades e as tecnologias utilizadas.

Figura 1. Versão desktop do módulo de upload de gabarito



Fonte: O autor.

Figura 2. Fluxo da detecção inicial e da segmentação SAM2



Fonte: O autor.

A segmentação SAM2 apresentada é apenas ilustrativa, conforme exibida no Roboflow; no código, a segmentação mantém a mesma similaridade.

4. Metodologia

A avaliação do pipeline concentrou-se inicialmente na eficácia do modelo de detecção de regiões de interesse. O YOLOv11s foi treinado para detectar `answer_area_enem` e

⁴Disponível em: <https://anonymous.4open.science/r/SBIE-75C6/Tabela2.md>

day_region, seguindo a metodologia *holdout* com 10% do dataset reservado para teste [Hastie et al. 2009]. Reconhece-se que o uso dessa abordagem sobre uma base reduzida representa uma limitação estatística relevante, uma vez que resultados próximos de 100% em amostras pequenas podem não refletir a robustez do modelo em cenários de maior variabilidade [Bishop 2006].

O dataset atual, composto por 90 imagens (sendo 9 para teste), cumpriu seu papel de verificação de viabilidade técnica e será tratado como contribuição do trabalho em sua versão expandida com imagens capturadas por diferentes modelos de *smartphones* e *layouts* de outros vestibulares, a ser disponibilizada publicamente ao final do treinamento. Técnicas de validação cruzada (*k-fold*) serão consideradas em versões futuras do estudo [Stone 1974]. A escolha do ENEM como escopo inicial justifica-se por sua escala nacional e alta padronização, características que o tornam ideal para a validação da viabilidade técnica do sistema.

No que se refere à arquitetura de processamento, o SAM2 já opera via API disponibilizada no HuggingFace, e os modelos YOLO são servidos por meio de arquivos de pesos pré-treinados. A migração completa do pipeline para uma infraestrutura em nuvem está planejada e representa uma evolução natural da arquitetura atual, viabilizando o uso autônomo da plataforma diretamente pelo *smartphone* do professor, sem dependência de processamento local.

4.1. Análise Quantitativa

Os resultados quantitativos são apresentados na tabela ⁵, disponível no repositório, que compara o desempenho entre o conjunto de teste do dataset original (imagens nunca vistas durante o treinamento) e imagens inéditas (9 novas imagens capturadas após o treinamento, fora do dataset). No conjunto de teste, o modelo alcançou precisão e revocação de 100%, com mAP@50⁶ de 0,9950, sem registrar falsos positivos ou negativos na matriz de confusão.

No cenário de imagens inéditas, que simula condições mais próximas do uso prático, os valores foram mAP@50 de 91,0% e mAP@50-95 de 90,0%, com confiança média de 90,95%, e novamente 18 verdadeiros positivos sem erros de classificação. Embora esses resultados indiquem boa capacidade de generalização dentro do escopo avaliado, a base de dados reduzida limita conclusões definitivas sobre a robustez do sistema frente a condições de captura e *layouts* não testados. No que se refere às etapas de OCR e OMR responsáveis, respectivamente, pela identificação do dia de aplicação e pela extração das respostas marcadas, ambos os módulos encontram-se em fase de desenvolvimento e integração ao pipeline conforme citado na Seção 3. Por serem as etapas que determinam diretamente a nota final do aluno, a avaliação quantitativa de sua acurácia constitui uma prioridade para as próximas iterações do trabalho, e seus resultados serão incorporados em versões futuras do estudo.

⁵Disponível em: <https://anonymous.4open.science/r/SBIE-75C6/Tabela3.md>

⁶mAP@50 (do inglês *mean Average Precision*) é a métrica de precisão média calculada considerando um limiar de *Intersection over Union* (IoU) de 50%. O mAP@50-95 corresponde à média do mAP calculada sobre múltiplos limiares de IoU, variando de 50% a 95% em incrementos de 5%, constituindo uma medida mais rigorosa da precisão de localização do modelo.

4.2. Análise Qualitativa

A configuração de protótipo de baixa fidelidade representa uma limitação metodológica: esse tipo de artefato pode não reproduzir a experiência real do sistema final, e o número reduzido de participantes restringe a generalização dos achados. Ainda assim, os insights obtidos foram relevantes para orientar o desenvolvimento. A correção automática foi percebida como a funcionalidade mais útil, com destaque para a economia de tempo como principal benefício.

Na fase exploratória foram conduzidas entrevistas semiestruturadas, com duração média de 20 minutos, complementadas por um roteiro estruturado com escala Likert [Likert 1932], com dois coordenadores pedagógicos e um professor. As sessões foram registradas por meio de gravação em áudio, complementada por anotações do entrevistador, o que possibilitou a análise posterior das respostas obtidas. Os participantes possuíam, em média, entre 1 e 5 anos de atuação em suas respectivas funções. Um dos entrevistados afirmou que “o sistema resolveria um problema real, pois atualmente gastamos horas corrigindo simulados manualmente”. Por outro lado, foram identificadas fragilidades na navegação entre telas, especialmente nos menus de exportação e visualização de relatórios, e ambos os participantes sinalizaram a necessidade de um painel mais completo, com histórico de desempenho por aluno e relatórios personalizados.

Cabe destacar que, na versão avaliada, o pipeline ⁷ de IA ainda opera de forma offline e não está totalmente integrado à plataforma Web, o que representa uma limitação prática relevante. Essas observações reforçam a necessidade de avançar na integração completa do pipeline em nuvem, na expansão da base de dados e na condução de avaliações com maior número de participantes em contexto real de uso. A tabela ⁸ resume as percepções coletadas sobre o protótipo a partir de um roteiro estruturado com escala Likert [Likert 1932], considerando as perguntas-base aplicadas aos participantes.

5. Contribuição da Pesquisa

A principal contribuição deste trabalho reside na democratização do acesso a tecnologias de ponta para a avaliação educacional, convertendo métodos avançados de Visão Computacional em uma ferramenta de uso cotidiano. Embora o *EduScore* se enquadre como uma pesquisa em estágio inicial de desenvolvimento alinhando-se à natureza de resultados emergentes, a plataforma já se apresenta em um estado praticamente funcional, operando com êxito utilizando um modelo fixo de detecção.

Do ponto de vista prático e pedagógico, o impacto imediato da solução é a drástica redução do tempo despendido por educadores e instituições na correção de simulados e atividades avaliativas. O processo tradicional de correção manual é exaustivo, demorado e inerentemente sujeito a falhas humanas que podem comprometer a lisura da avaliação. Ao automatizar essa etapa com alta precisão, o *EduScore* atua como um facilitador do trabalho docente, liberando o professor da carga operacional para que ele possa se concentrar no que realmente importa: a análise qualitativa do desempenho dos alunos e a elaboração de intervenções pedagógicas direcionadas com os dados obtidos ao final da

⁷Disponível em: <https://anonymous.4open.science/r/SBIE-75C6/fluxo%20completo%202.png>

⁸Disponível em: <https://anonymous.4open.science/r/SBIE-75C6/Tabela4.md>

captura de gabaritos. A arquitetura flexível baseada em inteligência artificial permite que o sistema seja facilmente adaptado para outros formatos de prova. Essa versatilidade torna o *EduScore* uma ferramenta altamente promissora para cenários de gestão pedagógica caracterizados por baixa aderência tecnológica ou infraestrutura limitada. Em avaliações da rede pública de ensino, por exemplo, onde a aquisição e manutenção de scanners ópticos comerciais são financeiramente inviáveis, a possibilidade de realizar correções em massa utilizando apenas a câmera de um *smartphone* comum representa um salto significativo na modernização e na equidade do acompanhamento escolar.

6. Cuidados Éticos

A avaliação qualitativa foi conduzida com dois profissionais de educação durante sessões de uso do protótipo inicial. Todos os participantes foram previamente informados sobre os objetivos da pesquisa e assinaram o Termo de Consentimento Livre e Esclarecido (TCLE). Este estudo foi conduzido em conformidade com a Resolução nº 510/2016 do Conselho Nacional de Saúde, que regulamenta pesquisas em Ciências Humanas e Sociais, sendo considerado isento de submissão ao Comitê de Ética em Pesquisa (CEP), nos termos do Art. 1º, Parágrafo Único, da referida resolução, por tratar-se de pesquisa educacional com dados anonimizado. A participação foi voluntária, com liberdade de desistência sem prejuízo, e os dados foram tratados de forma anonimizada, garantindo confidencialidade e conformidade com os princípios éticos.

7. Considerações Finais

Este artigo apresentou o *EduScore*, uma plataforma para automação da correção de cartões-resposta de exames de admissão ao ensino superior. Como principal resultado, destaca-se que a plataforma Web já se encontra parcialmente operacional para gestão de dados educacionais, contando com um módulo de correção baseado em OpenCV para um modelo fixo de 60 questões. As técnicas de inteligência artificial descritas neste trabalho ainda operam de forma *offline*, estando em fase de integração ao pipeline principal da aplicação.

Por tratar-se de um estudo piloto exploratório, o trabalho apresenta limitações inerentes ao seu estágio de desenvolvimento. A validação foi conduzida com amostragem reduzida e utilizando um protótipo de baixa fidelidade, demandando novas rodadas de testes com o sistema totalmente integrado para conclusões mais robustas. Apesar disso, os resultados preliminares indicam potencial para redução do tempo gasto em processos de correção manual de simulados e avaliações objetivas, especialmente em contextos educacionais com baixa aderência tecnológica ou infraestrutura limitada. Inicialmente voltado ao ENEM, o *EduScore* possui arquitetura adaptável para outros vestibulares e cenários de gestão pedagógica da rede pública ou institucional.

Como trabalhos futuros, planeja-se: (i) o treinamento e a integração de modelos específicos para os vestibulares do [Omitido para avaliação]; (ii) a implementação de detecção em tempo real (*live detect*) no módulo mobile; (iii) a validação do sistema completo com um grupo ampliado de professores em ambiente real; e (iv) a expansão do dataset para maior diversidade de *layouts* e condições de captura. Com essas evoluções, espera-se consolidar o *EduScore* como uma ferramenta acessível, escalável e eficaz para instituições de ensino com recursos tecnológicos limitados.

8. Declaração sobre o uso de Inteligência Artificial

Declaramos que as ferramentas de Inteligência Artificial (IA) não foram utilizadas para a escrita deste artigo. Os autores prezaram pela autoria e originalidade. O processo metodológico, envolvendo a aplicação, a análise e a interpretação de dados, foi realizado sem a assistência de ferramentas de IA. De modo análogo, o conteúdo científico foi escrito exclusivamente pelos autores, assim como as afirmações, conclusões e outras seções deste artigo. O uso de ferramentas de IA generativa restringiu-se ao apoio para checagem de fontes, depuração de erros de decodificação em relação aos algoritmos dos pipelines de imagem.

Referências

- Abreu, F. M. d., Chagas, M. J. M. d., Silva, P. A. M. d., Conte, H. N. M. d. S., and Conte, T. N. M. d. S. (2025). Detector de gabaritos utilizando Roboflow e Google Colab. *Contribuciones a las Ciencias Sociales*, 18(7):e19594.
- Bernardino, R., Lins, R. D., and Barboza, R. d. S. (2023). A quality, size and time assessment of the binarization of documents photographed by smartphones. *Journal of Imaging*, 9(2):41.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3):319–340.
- Fileno, G. C., Barbosa, K. E. B., Silva, R. A. G. d., Ferreira, H. L. E., and Marques, J. (2025). Sistema automatizado de provas de múltipla escolha com embaralhamento inteligente de gabaritos. In *Anais do VI Workshop sobre as Implicações da Computação na Sociedade (WICS)*, pages 330–335. SBC.
- Garrett, J. J. (2010). *The Elements of User Experience: User-Centered Design for the Web and Beyond*. New Riders, 2nd edition.
- Hastie, T., Tibshirani, R., and Friedman, J. (2009). *The Elements of Statistical Learning*. Springer.
- ISTOÉ (2020). Presidente do inep diz que “erro de associação” causou problemas na correção de provas do Enem. Acessado em: 28 maio 2026.
- Junior, I. A. S. (2014). Estudo da viabilidade do uso de um OCR na placa BeagleBoard e sua integração no xlua embarcado. Monografia de Bacharelado. Orientador: Prof. Marcio Seiji Oyamada.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Proceedings of the 25th International Conference on Neural Information Processing Systems*, pages 1097–1105. Curran Associates Inc.
- Likert, R. (1932). A technique for the measurement of attitudes. *Archives of Psychology*, 140:1–55.
- Mondal, S., De, P., Malakar, S., et al. (2024). OMRNet: a lightweight deep learning model for optical mark recognition. *Multimedia Tools and Applications*, 83:14011–14045.

- Oliveira, A. P. d. and Silva, G. S. V. d. (2024). Avalia: sistema de correção automatizada de atividades escolares utilizando reconhecimento óptico de caracteres e inteligência artificial. Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação). Orientadora: Simone das Graças Domingues Prado; Coorientador: José Remo Ferreira Brega.
- Oliveira, E., Bindá, J., Lopes, R., and Valle, E. (2020). Paperclickers: Affordable solution for classroom response systems. *Computer Applications in Engineering Education*, 28:1520–1535.
- Rajagopal, R. D. and Saha, B. (2024). Optical mark recognition (OMR) automated grading using OpenCV. In *AIP Conference Proceedings*, volume 3075, page 020200.
- Rangel, H. (2021). Desenvolvimento de um sistema automático de correção de folhas de respostas de provas objetivas. Trabalho de Conclusão de Curso (Graduação), 87 f.
- Ravi, N., Gabeur, V., Hu, Y.-T., Hu, R., Ryali, C., Ma, T., Khedr, H., Rädle, R., Rolland, C., Gustafson, L., Mintun, E., Pan, J., Alwala, K. V., Carion, N., Wu, C.-Y., Girshick, R., Dollár, P., and Feichtenhofer, C. (2024). SAM 2: Segment anything in images and videos. *arXiv preprint arXiv:2408.00714*.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 779–788.
- Smith, R. (2007). An overview of the tesseract OCR engine. *Proceedings of the International Conference on Document Analysis and Recognition (ICDAR)*, pages 629–633.
- Stone, M. (1974). Cross-validatory choice and assessment of statistical predictions. *Journal of the Royal Statistical Society: Series B*, 36(2):111–147.
- Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*. Springer.
- UOL Educação (2020). Weintraub: erro na correção do Enem 2019 afetou cerca de 6 mil candidatos. Acessado em: 28 maio 2026.
- Wang, W., Zheng, V. W., Yu, H., and Miao, C. (2019). A survey of zero-shot learning: Settings, methods, and applications. *ACM Transactions on Intelligent Systems and Technology*, 10(2):1–37.
- Wigington, C. (2024). Handheld video document scanning: A robust on-device model for multi-page document scanning. *arXiv preprint arXiv:2411.00576*.