

Relato de Experiência: Aprendizagem Ativa no Ensino de Visão Computacional com Cascade e HOG

Matheus Souza Lima

Instituto Federal de Educação, Ciência e Tecnologia do Amazonas - Campus
Manaus Zona Leste
Manaus, Amazonas, Brasil
matheuslima060604@gmail.com

Matheus Freitas de Menezes

Universidade Federal do Amazonas,
Instituto de Computação
Manaus, Amazonas, Brasil
matheusfreitasam@gmail.com

Luana Rodrigues Aguiar

Instituto Federal de Educação, Ciência e Tecnologia do Amazonas - Campus
Manaus Zona Leste
Manaus, Amazonas, Brasil
luana.aguiar2506@gmail.com

José Elislande Breno de Souza

Linhares

Instituto Federal de Educação, Ciência e Tecnologia do Amazonas - Campus
Manaus Zona Leste
Manaus, Amazonas, Brasil
breno.linhares@ifam.edu.br

Fabiann Matthaus Dantas

Barbosa

Instituto Federal de Educação, Ciência e Tecnologia do Amazonas - Campus
Manaus Zona Leste
Manaus, Amazonas, Brasil
fabiann.dantas@ifam.edu.br

ABSTRACT

Computer vision, a growing field in artificial intelligence, is crucial in sectors such as healthcare and security. This article describes the application of active teaching methodology in a short course on computer vision, involving 26 Software Engineering students. The course covered the techniques of Cascade Classifier and Histogram of Oriented Gradients (HOG), integrating theory and practice over 20 hours of activities. The effectiveness of the course was evaluated through quantitative and qualitative analyses. Quantitative results showed a significant improvement in students' performance, while qualitative analysis indicated an increase in practical skills and understanding of the techniques, despite challenges related to theoretical workload and activity support. The practical approach was praised, with suggestions to improve the teaching materials and support during activities.

PALAVRAS-CHAVE

Active Learning, Computer Vision, Short Course.

1 INTRODUÇÃO

A visão computacional, um dos campos mais promissores da inteligência artificial, permite que as máquinas processem, compreendam e interpretem o conteúdo de imagens e vídeos, imitando a capacidade humana de visão [1]. Com os constantes avanços tecnológicos, essa área tem encontrado uma gama crescente de aplicações em diversos setores, como saúde, segurança, automotivo, agropecuário, entre outros [2]. Sistemas de visão computacional têm desempenhado um papel crucial em aplicações como reconhecimento facial, análise de tráfego e segurança, permitindo que computadores interpretem e analisem informações visuais de maneira eficaz [3].

Nesse contexto, a formação de profissionais capacitados para lidar com os desafios dessa tecnologia se tornou fundamental. Para atender às crescentes demandas do mercado e para o avanço da pesquisa, é essencial que os profissionais compreendam e apliquem técnicas de visão computacional de forma prática. Dentre as abordagens mais utilizadas, destacam-se o *Cascade Classifier*, conhecido

por sua rapidez e eficácia em detecção de objetos, e o *Histogram of Oriented Gradients* (HOG), amplamente reconhecido por sua robustez na extração de características para detecção.

Neste minicurso, foi aplicada a metodologia ativa de ensino, que promove o engajamento dos alunos em atividades práticas, incentivando a participação direta no processo de aprendizagem. Ao contrário dos métodos tradicionais, onde o aluno assume um papel passivo, a aprendizagem ativa envolve o estudante em atividades colaborativas e na resolução de problemas, o que favorece a aplicação prática dos conceitos [4]. Essa abordagem foi utilizada ao longo do curso para proporcionar aos alunos a oportunidade de aprender tanto pela teoria quanto pela prática, consolidando os conceitos de visão computacional em um ambiente controlado.

O minicurso foi conduzido ao longo de cinco dias, com 4 horas de aula diárias, totalizando 20 horas de conteúdo. Participaram 26 alunos do curso de Engenharia de Software, todos iniciantes no tema de visão computacional. Durante o curso, os alunos tiveram a oportunidade de tirar dúvidas, implementar e testar as técnicas de *Cascade Classifier* e HOG, experimentando de forma prática os conceitos aprendidos.

A eficácia da metodologia ativa foi avaliada por meio de uma análise quantitativa, com a aplicação de um pré-teste e pós-teste, além de uma análise qualitativa, realizada através de um questionário que coleta o *feedback* dos participantes sobre o minicurso. Para garantir a transparência e a ética no processo, todos os participantes foram informados previamente sobre os objetivos da pesquisa e assinaram um Termo de Consentimento Livre e Esclarecido (TCLE), assegurando sua participação voluntária e consciente. Com isso, buscou-se identificar os impactos dessa abordagem no aprendizado e na percepção dos alunos em relação ao conteúdo abordado.

O restante deste artigo está organizado da seguinte forma. A Seção 2 apresenta conceitos sobre visão computacional, técnicas e aprendizagem ativa. A Seção 3 descreve a prática feita em sala de aula. Em seguida, a Seção 4 apresenta a análise quantitativa dos resultados do estudo enquanto na Seção 5 mostra análise qualitativa. Finalmente, na Seção 6, é apresentada as conclusões desta pesquisa.

2 CONCEITOS RELACIONADOS

2.1 Visão Computacional

A visão computacional é um campo da inteligência artificial e da ciência da computação que busca ensinar as máquinas a “verem” e interpretarem imagens e vídeos da mesma forma que os humanos [5]. Esse ramo da IA envolve o desenvolvimento de algoritmos e técnicas para processar e analisar informações visuais, com o objetivo de extrair dados significativos de imagens estáticas ou sequências de vídeo. Em essência, a visão computacional tenta replicar as capacidades do sistema visual humano, utilizando ferramentas matemáticas e computacionais para realizar tarefas como a detecção, o reconhecimento e o rastreamento de objetos [6]. Essas tarefas são fundamentais para muitas aplicações práticas em diversas áreas, como segurança, saúde, transportes e agricultura.

O processo de detecção é o primeiro passo na análise visual e refere-se à identificação da presença de um objeto ou padrão em uma imagem ou vídeo [7]. Após a detecção, entra o processo de reconhecimento, que tem como objetivo identificar e classificar o objeto detectado [8]. Por exemplo, após identificar a presença de um rosto em uma imagem, o sistema pode determinar a identidade da pessoa com base em suas características faciais. O terceiro processo fundamental é o rastreamento, que permite acompanhar um objeto ao longo do tempo, por meio de uma sequência de imagens ou vídeos [9]. Esse processo é crucial para aplicações em tempo real, como a vigilância por câmeras ou a navegação de veículos autônomos.

A visão computacional utiliza uma combinação de técnicas de processamento de imagens, extração de características e aprendizado de máquina para realizar suas tarefas [8]. O processamento de imagens é essencial para preparar as imagens para análise, aplicando filtros e técnicas para melhorar a qualidade visual e remover ruídos. A extração de características, por sua vez, identifica elementos essenciais na imagem, como bordas e texturas, que ajudam a distinguir objetos [10]. Modelos de aprendizado de máquina, como redes neurais convolucionais (CNNs), têm sido cada vez mais aplicados na área, permitindo que sistemas de visão computacional se tornem mais precisos e eficientes em tarefas complexas, como o reconhecimento de padrões em imagens de alta variação.

Apesar dos avanços, a visão computacional ainda enfrenta desafios significativos. Um dos principais obstáculos é a variação de iluminação, que pode alterar drasticamente as características visuais de uma cena, tornando mais difícil a análise correta das imagens. Além disso, objetos podem estar ocultos ou sobrepostos, o que dificulta sua detecção e rastreamento [11]. Outro desafio é a ambiguidade nas imagens, em que sombras ou distorções podem tornar a interpretação visual mais complexa. A escalabilidade e a eficiência computacional também são questões cruciais, já que processar grandes volumes de imagens ou vídeos em tempo real requer otimização dos algoritmos, de modo que não haja perda de desempenho. Mesmo com esses desafios, a visão computacional continua a se expandir e evoluir, sendo uma das áreas mais promissoras da inteligência artificial.

No contexto educacional, a inclusão da visão computacional nas grades curriculares dos cursos de computação é essencial para preparar os alunos para enfrentar os desafios tecnológicos do futuro. A medida que a tecnologia avança e as aplicações de visão computacional se tornam cada vez mais presentes no cotidiano, a formação

de profissionais capacitados nessa área é crucial para o desenvolvimento de soluções inovadoras. Ensinar os conceitos fundamentais e as técnicas de visão computacional em cursos de graduação e pós-graduação permite que os alunos adquiram as habilidades necessárias para criar sistemas inteligentes capazes de processar e interpretar informações visuais de forma eficiente. Além disso, a integração de atividades práticas, como a implementação de algoritmos em cursos de computação, proporciona uma experiência real de desenvolvimento, permitindo que os alunos vejam na prática como essas teorias se aplicam a problemas do mundo real.

2.2 Cascade Classifier

O *Cascade Classifier* é uma abordagem eficiente e amplamente utilizada para a detecção de objetos em imagens e vídeos. Essa técnica foi inicialmente proposta por Paul Viola e Michael Jones em 2001 e baseia-se em um processo hierárquico, onde classificadores simples e rápidos são organizados em cascata para identificar a presença de padrões específicos [12]. Cada nível da cascata elimina regiões que provavelmente não contêm o objeto de interesse, permitindo uma análise mais detalhada apenas nas áreas promissoras.

O processo de treinamento de um *Cascade Classifier* geralmente utiliza a técnica de *boosting*, como o *AdaBoost*, para combinar múltiplos classificadores fracos em um classificador mais robusto [13]. Além disso, são empregadas janelas deslizantes para analisar diferentes partes da imagem em busca de objetos. Uma característica marcante desse método é o uso de descritores simples, como as *features of Haar*, que são computacionalmente leves [14].

No contexto da aprendizagem ativa para o ensino de visão computacional, o *Cascade Classifier* pode ser explorado para demonstrar como algoritmos de detecção de objetos são estruturados e otimizados. Atividades práticas podem incluir a coleta de conjuntos de dados para treinamento, a compreensão dos parâmetros envolvidos no processo e a avaliação do desempenho do modelo em diferentes cenários.

2.3 Histogram of Oriented Gradientes (HOG)

HOG é uma técnica de descrição de imagem amplamente utilizada para a detecção de padrões e reconhecimento de objetos. Introduzido por Navneet Dalal e Bill Triggs em 2005, o HOG baseia-se na análise da distribuição local de gradientes e orientações de bordas em uma imagem [15]. Essa abordagem é especialmente eficaz para capturar características estruturais e texturais, tornando-a popular em aplicações como a detecção de pedestres.

O processo de extração de *features* com HOG envolve etapas como a divisão da imagem em pequenas regiões chamadas “células”, o cálculo do histograma de orientações para cada célula e a normalização dos histogramas com base em blocos adjacentes [16]. Isso resulta em uma representação robusta e invariante a alterações de iluminação e pequenas transformações geométricas.

Para o ensino de visão computacional utilizando aprendizagem ativa, o HOG oferece uma excelente oportunidade para explorar conceitos fundamentais de processamento de imagem e extração de *features*. Os alunos podem participar de atividades como a implementação do algoritmo, a visualização de gradientes em imagens e a integração do descritor em sistemas de classificação e detecção de objetos. Essas experiências práticas permitem uma compreensão

mais profunda do impacto de descritores na precisão e eficácia dos modelos de visão computacional.

2.4 Aprendizagem Ativa

A aprendizagem ativa é uma abordagem educacional que coloca o estudante no centro do processo de aprendizagem, incentivando-o a ser o protagonista da sua própria construção de conhecimento. Em vez de ser um receptor passivo de informações, o aluno participa ativamente de atividades que exigem envolvimento direto com o conteúdo, como debates, estudos de caso, resolução de problemas práticos e trabalhos em grupo [11]. Na área de computação, essa abordagem é particularmente eficaz, pois permite que os alunos apliquem os conceitos teóricos de maneira prática e vivenciem o processo de resolução de problemas complexos que são comuns na profissão. Ao trabalhar com exemplos reais, os alunos conseguem perceber a relevância do aprendizado e desenvolver habilidades essenciais para sua futura carreira.

Um exemplo claro de aprendizagem ativa em computação é a realização de projetos práticos, como a construção de *software*, o desenvolvimento de algoritmos ou a implementação de sistemas complexos [17]. Essas atividades não só reforçam os conhecimentos adquiridos, mas também permitem que os alunos lidem com desafios reais, como a otimização de código, a depuração de erros e a integração de sistemas. Em vez de simplesmente ler ou ouvir sobre os tópicos, os alunos têm a oportunidade de "fazer", o que lhes proporciona uma compreensão mais profunda e duradoura dos conceitos abordados. Essa experiência prática prepara os alunos para lidar com os desafios cotidianos da profissão, como a criação de programas eficientes ou a solução de problemas técnicos em sistemas computacionais.

Outro aspecto importante da aprendizagem ativa em computação é a aprendizagem colaborativa, onde os alunos trabalham em grupos para resolver problemas e desenvolver projetos em conjunto [18]. A computação é uma área altamente colaborativa, e a capacidade de trabalhar em equipe é essencial no desenvolvimento de *software*, em pesquisas de inovação tecnológica ou até mesmo em ambientes de trabalho ágeis. Ao realizar atividades de grupo, os estudantes têm a oportunidade de compartilhar conhecimentos, discutir soluções e aprender uns com os outros, promovendo habilidades essenciais como comunicação, trabalho em equipe e liderança, que são altamente valorizadas no mercado de trabalho de tecnologia.

Além disso, a aprendizagem ativa em computação pode ser aplicada por meio do uso de ferramentas como ambientes de programação interativos, simulações, *hackathons* e projetos de código aberto. Essas ferramentas permitem que os alunos experimentem e aprendam de forma prática, enfrentando desafios reais e recebendo *feedback* imediato. Essa abordagem também pode ser aplicada em disciplinas como Inteligência Artificial, Engenharia de *Software* e Cibersegurança, onde os alunos podem desenvolver soluções para problemas complexos e aprender a importância de metodologias como a ágil ou o desenvolvimento contínuo. A aprendizagem ativa prepara, assim, os alunos para se tornarem profissionais autônomos e capazes de aplicar seus conhecimentos de forma eficiente e criativa no desenvolvimento de soluções tecnológicas.

3 DESENVOLVIMENTO DO MINICURSO

O minicurso de visão computacional foi estruturado de maneira a proporcionar aos alunos uma introdução prática e teórica ao campo da visão computacional, utilizando abordagens de aprendizagem ativa. A metodologia de aprendizagem ativa visa engajar os alunos de forma mais dinâmica e colaborativa, permitindo que se tornem protagonistas do próprio aprendizado. O minicurso abordou desde os conceitos fundamentais da área até a implementação de algoritmos práticos de detecção de objetos, promovendo uma experiência educacional mais interativa e aplicável. A Figura 1 exibe alguns alunos sendo atendidos durante o curso.

Este minicurso foi realizado para alunos da graduação em Engenharia de *Software*, com uma carga horária de 5 dias, totalizando 20 horas de aulas (4 horas por dia), contando com 26 participantes. O conteúdo foi distribuído entre teoria e prática, com foco na aplicação de algoritmos de visão computacional em problemas reais. A Figura 2 exibe a sala onde foi realizado o minicurso.



Figura 1: Instrutor auxiliando os estudantes durante a atividade.

3.1 Introdução à visão computacional e suas aplicações

O minicurso começou com uma apresentação teórica sobre o campo da visão computacional, destacando seus conceitos básicos e as diversas aplicações da tecnologia. A visão computacional envolve o uso de algoritmos e modelos matemáticos para possibilitar que as máquinas "vejam", e interpretarem imagens digitais, replicando, de certa forma, a percepção visual humana.

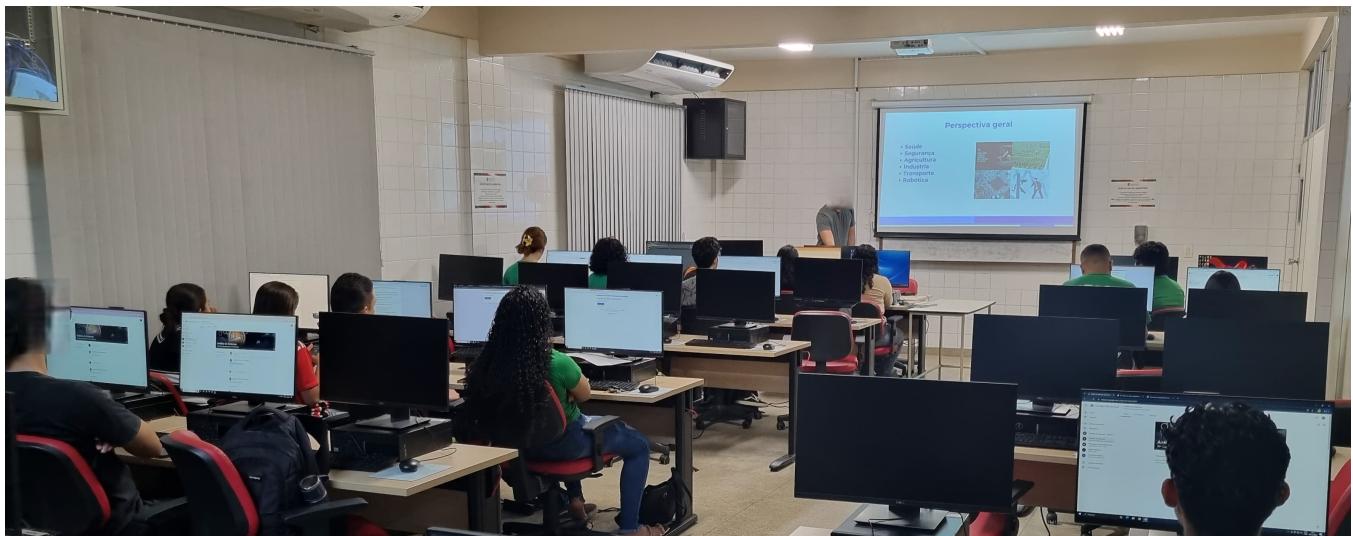


Figura 2: Sala onde foi realizado o minicurso.

Foram discutidos exemplos de aplicações que ilustram a importância dessa tecnologia em diferentes setores, como na saúde, com sistemas de diagnóstico baseados em imagens médicas, e na segurança, com o uso de reconhecimento facial. A área também tem forte presença em tecnologias emergentes, como veículos autônomos e sistemas de monitoramento na agricultura. O objetivo dessa etapa foi proporcionar aos alunos uma visão abrangente do impacto que a visão computacional tem no mundo real, e como ela continua a evoluir à medida que novas técnicas e ferramentas surgem.

Em seguida, os alunos foram introduzidos a três processos principais envolvidos na visão computacional: detecção, reconhecimento e rastreamento de objetos. Estes são componentes fundamentais em qualquer aplicação de visão computacional, sendo essenciais para a análise e compreensão de imagens e vídeos.

3.2 Ensino ativo e aplicações práticas

A aprendizagem ativa foi aplicada de forma intensa na sequência do minicurso, quando os alunos foram orientados a implementar os algoritmos discutidos teoricamente. A abordagem prática foi fundamental para solidificar o aprendizado dos conceitos abordados, promovendo um ambiente onde os alunos puderam aprender fazendo.

Uma das primeiras abordagens práticas foi a implementação do algoritmo de cascata para detecção de objetos. Este algoritmo utiliza uma sequência de classificadores fracos, que são aplicados de forma progressiva para identificar objetos nas imagens. Durante a explicação teórica, os alunos aprenderam sobre a importância da filtragem rápida de áreas irrelevantes nas imagens, utilizando características simples como bordas e contrastes. O uso de *Haar-like features*, comumente utilizado na detecção de faces, foi explorado como parte dessa técnica.

Na parte prática, o *Google Colab* foi utilizado como plataforma de desenvolvimento, permitindo que os alunos executassem os códigos diretamente no navegador, sem a necessidade de instalações locais.

Essa escolha visou facilitar o acesso e a execução do código de forma simplificada. Os alunos foram guiados nas seguintes etapas:

- **Configuração do Ambiente:** A primeira ação foi importar as bibliotecas necessárias, com destaque para o OpenCV, que contém funções específicas para a manipulação de imagens e a aplicação dos algoritmos de visão computacional.
- **Carregamento de Imagens:** Os alunos aprenderam a carregar imagens e vídeos no *Google Colab* usando a função `cv2.imread()`, para posteriormente aplicarem os algoritmos de detecção.
- **Detecção com Cascata:** Os alunos utilizaram arquivos XML pré-treinados, que continham os classificadores *Haar Cascade*, e aplicaram a função `detectMultiScale()`, do OpenCV, para detectar objetos em diferentes escalas da imagem. O processo foi conduzido de maneira passo a passo, desde a configuração dos parâmetros de detecção até a implementação de retângulos de delimitação para marcar os objetos detectados.

A metodologia de ensino ativo, combinada com a aplicação prática desses conceitos, incentivou os alunos a se engajarem diretamente com o código, realizando experimentações e ajustando os parâmetros para observar os efeitos em tempo real.

O próximo tópico abordado foi o algoritmo HOG (*Histogram of Oriented Gradients*), que é amplamente utilizado para detecção de objetos com características geométricas bem definidas, como pedestres. Durante a explicação teórica, os alunos aprenderam que o HOG captura informações sobre a distribuição e a direção dos gradientes de intensidade nas imagens, fornecendo uma descrição robusta das características dos objetos.

Na etapa prática, os alunos foram novamente orientados a implementar o algoritmo HOG utilizando o *Google Colab*. As etapas de implementação incluíram:

- **Importação das Bibliotecas:** As bibliotecas necessárias, como o OpenCV e o dlib, foram carregadas para possibilitar

o processamento das imagens e a extração das características HOG.

- **Leitura e Pré-processamento das Imagens:** As imagens foram preparadas para garantir que estivessem em um formato adequado para a extração das características HOG.
- **Extração de Características com HOG:** A função `hog()` do dlib foi usada para calcular os histogramas de gradientes. A detecção foi então realizada utilizando o classificador HOG para localizar pedestres ou outros objetos de interesse.
- **Visualização dos Resultados:** Similar à etapa anterior, os resultados da detecção foram visualizados com caixas delimitadoras sobre os objetos detectados, permitindo que os alunos verificassem visualmente a eficácia do algoritmo.

O minicurso de visão computacional, estruturado com o uso de aprendizagem ativa, proporcionou aos alunos uma introdução aos conceitos e práticas dessa área da inteligência artificial. Ao longo das aulas, os participantes tiveram a oportunidade de explorar tanto a teoria por trás dos algoritmos de detecção de objetos quanto a implementação prática desses algoritmos, utilizando ferramentas acessíveis como o *Google Colab*. Embora o minicurso tenha sido breve, com uma carga horária de 20 horas, espera-se que tenha contribuído para despertar o interesse dos alunos pela área e oferecido uma base para futuras investigações e aprendizados em visão computacional.

4 ANÁLISE QUANTITATIVA

Para avaliar a eficácia do minicurso de Visão Computacional e o impacto da aprendizagem ativa na melhoria do desempenho dos alunos, foi realizada uma análise estatística comparando as notas obtidas pelos participantes no pré-teste e no pós-teste. O pré-teste foi aplicado antes da implementação dos conceitos de visão computacional, enquanto o pós-teste foi aplicado após a realização da atividade prática, que envolveu a implementação de dois algoritmos de detecção de objetos.

4.1 Teste de Hipótese

Para avaliar se houve uma diferença significativa entre as notas do pré-teste e do pós-teste, foi realizado o Teste de *Wilcoxon* para amostras pareadas, um teste não paramétrico que compara duas amostras dependentes. Este teste foi escolhido devido à natureza dos dados, que não seguem uma distribuição normal, o que torna o Teste *t* de *Student* inadequado. O objetivo era verificar se o minicurso foi eficaz em promover melhorias significativas no desempenho dos alunos.

A hipótese nula (H_0) foi formulada da seguinte forma: "Não há diferença significativa entre as notas do pré-teste e do pós-teste dos alunos", enquanto a hipótese alternativa (H_1) afirmava: "Há uma diferença significativa entre as notas do pré-teste e do pós-teste dos alunos".

A análise foi conduzida utilizando a função `wilcoxon()` da biblioteca *scipy* no *Python*, que calcula a estatística do teste de *Wilcoxon* e o *valor-p* correspondente. Os resultados obtidos foram os seguintes:

- Estatística de *Wilcoxon*: 7.5
- *Valor-p*: 5.66×10^{-7}

4.2 Interpretação dos Resultados

O valor-p obtido foi muito abaixo do nível de significância comum de 0.05, o que nos permite rejeitar a hipótese nula. Isso significa que há uma diferença estatisticamente significativa entre as notas do pré-teste e do pós-teste, indicando que o minicurso teve um impacto positivo no desempenho dos alunos. O valor-p extremamente baixo sugere que a probabilidade de que essa diferença tenha ocorrido por acaso é extremamente pequena, o que reforça a eficácia do curso.

Ao analisar os dados das notas do pré-teste e pós-teste de todos os participantes (ver Tabela 1), observa-se uma tendência geral de melhoria nas pontuações. A maioria dos alunos teve um aumento nas suas notas, com algumas exceções, como o Participante 3 (P3), que apresentou uma ligeira melhoria de 2.3 para 2.5, e o Participante 7 (P7), que teve uma pequena queda de 4.2 para 4.0. Embora esses resultados isolados não comprometam a conclusão geral, é interessante notar que a grande maioria dos participantes demonstrou progresso após a realização das atividades práticas.

Tabela 1: Tabela com as notas dos participantes.

Participante	Nota Antes	Nota Depois
P1	3.2	4.5
P2	4.5	7.8
P3	2.3	2.5
P4	5.6	8.2
P5	1.8	4.5
P6	0.7	3.2
P7	4.2	4.0
P8	2.8	5.4
P9	3.9	3.8
P10	1.5	4.0
P11	2.6	6.3
P12	4.8	7.1
P13	3.0	6.0
P14	0.5	3.8
P15	2.4	3.0
P16	5.0	4.5
P17	3.3	6.2
P18	1.0	4.0
P19	4.1	7.0
P20	2.7	5.3
P21	3.5	7.0
P22	4.6	7.5
P23	1.2	4.2
P24	3.4	6.8
P25	5.2	8.0
P26	0.9	3.9

Em termos de melhoria média, os participantes que tinham notas iniciais mais baixas, como os Participantes 6 (P6) e 14 (P14), experimentaram aumentos notáveis. Por exemplo, o Participante 6 passou de 0.7 para 3.2, refletindo um aumento considerável de seu conhecimento durante o minicurso. A Figura 3 exibe um *boxplot* que demonstra o crescimento da nota após a realização do curso.

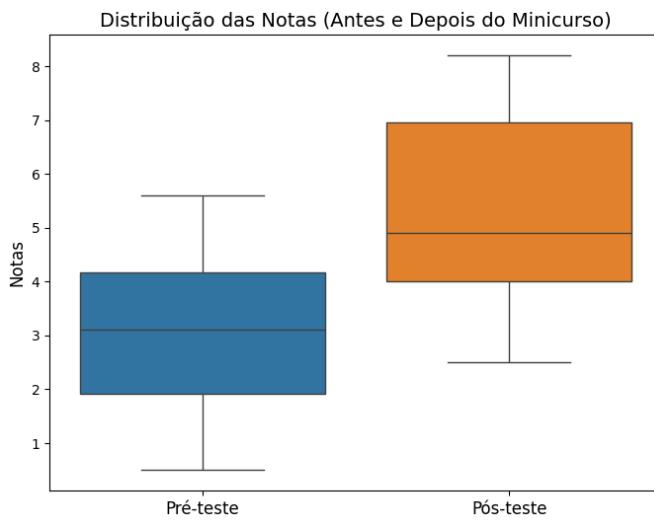


Figura 3: Boxplot das notas de pré-teste e pós-teste dos participantes.

4.3 Conclusão da Análise Quantitativa

Os resultados do teste de *Wilcoxon*, juntamente com a análise dos dados individuais, indicam que o minicurso de Visão Computacional, implementado com métodos de aprendizagem ativa, foi eficaz em melhorar o desempenho dos alunos. Isso demonstra o valor de integrar atividades práticas, como a implementação de algoritmos de visão computacional, no processo de ensino-aprendizagem, especialmente em áreas complexas da computação, como a inteligência artificial e a visão computacional.

A eficácia do minicurso foi destacada pelo aumento das notas, que, mesmo considerando a variação entre os participantes, mostram uma tendência geral de avanço no conhecimento. A análise estatística, suportada pelo valor-p significativo, reforça a conclusão de que os alunos se beneficiaram do curso, adquirindo uma compreensão mais profunda da visão computacional e suas aplicações.

5 ANÁLISE QUALITATIVA

A análise qualitativa conduzida para avaliar a percepção de aprendizado e o valor percebido pelos alunos no minicurso de Visão Computacional revelou diversas nuances sobre o impacto da metodologia ativa utilizada no curso. As respostas dos participantes foram detalhadas e forneceram informações sobre as vantagens e desafios enfrentados durante o experimento. Entre os 26 alunos, 12 forneceram *feedback*, o que permitiu uma análise representativa dos efeitos da abordagem adotada.

5.1 Percepção de Aprendizado

O principal objetivo da primeira parte da análise foi entender a evolução das habilidades dos participantes em relação às técnicas de visão computacional abordadas no minicurso. A grande maioria dos alunos indicou uma melhoria significativa nas suas habilidades, com destaque para a implementação prática das técnicas de *Cascade Classifier* e *HOG*.

A aluna do grupo 1 destacou a importância do aprendizado prático para a compreensão teórica dos conceitos: “A abordagem de aprendizagem ativa foi essencial para meu aprendizado. Implementar as técnicas me ajudou a entender os conceitos mais rapidamente do que apenas estudá-los teoricamente.” Essa afirmação reflete a experiência de muitos alunos, que sentiram que a aprendizagem ativa, com ênfase em atividades práticas e discussões em grupo, foi decisiva para a consolidação do conteúdo. A prática e a troca de experiências entre os participantes emergiram como um fator chave na assimilação das técnicas.

No entanto, alguns alunos relataram dificuldades durante o processo, principalmente na fase de implementação prática. A aluna do grupo 2 comentou: “Acho que houve uma melhora moderada. Consegui entender melhor os fundamentos, mas senti dificuldade na implementação prática, especialmente no ajuste dos parâmetros.” Esse tipo de *feedback* sugere que, embora a metodologia ativa tenha sido eficaz, o nível de complexidade das tarefas práticas exigiu mais tempo e suporte para uma compreensão completa.

A evolução das habilidades foi bem documentada por participantes que já possuíam algum conhecimento prévio na área. A aluna do grupo 5, por exemplo, afirmou: “Melhorei minha habilidade de comparar diferentes técnicas. O experimento ajudou a aprofundar meu entendimento.” Essa afirmação reflete a sensação de muitos participantes de que o minicurso não só reforçou os conceitos, mas também os preparou para aplicar as técnicas em cenários mais complexos.

5.2 Valor percebido

A segunda parte da análise focou no valor percebido do aprendizado para a formação acadêmica e profissional dos participantes. As respostas variaram de acordo com os interesses individuais de cada aluno, mas, de maneira geral, todos reconheceram a relevância do conteúdo abordado para suas trajetórias profissionais.

A aluna do grupo 3 foi clara ao expressar a importância do conteúdo para sua futura carreira: “Extremamente relevante, já que estou interessado em trabalhar com inteligência artificial e visão computacional no futuro.” A aplicabilidade do aprendizado para áreas emergentes, como inteligência artificial, automação e análise de imagens médicas, foi um ponto destacado por vários participantes, reforçando o valor prático do minicurso para suas futuras atuações profissionais.

A percepção do valor do aprendizado foi especialmente positiva entre os alunos que manifestaram interesse em áreas como automação e inteligência artificial. A aluna do grupo 4 comentou: “É um conhecimento essencial, principalmente porque abre portas para explorar aplicações em áreas como automação e análise de imagens médicas.” Além disso, muitos alunos afirmaram que o minicurso agregou valor ao seu conhecimento sobre as técnicas de visão computacional. A aluna do grupo 9, por exemplo, disse: “O estudo agregou valor, pois me deu confiança para explorar mais a fundo técnicas de visão computacional.”

Entretanto, também houve algumas críticas em relação à profundidade do conteúdo apresentado. A aluna do grupo 8, por exemplo, sentiu que a abordagem poderia ter sido mais detalhada em alguns aspectos: “Considero importante, mas acredito que uma abordagem mais detalhada na configuração das técnicas poderia agregar ainda

mais valor." Esse tipo de comentário sugere que, para alguns participantes, uma maior profundidade teórica poderia ter enriquecido a compreensão das aplicações práticas.

5.3 Pontos negativos

Embora os *feedbacks* tenham sido amplamente positivos, alguns pontos negativos também foram levantados pelos participantes. Entre as principais dificuldades relatadas, destacam-se a carga teórica insuficiente, o desequilíbrio na divisão de tarefas e a falta de materiais de apoio durante as atividades práticas.

A aluna do grupo 6 expressou uma das principais críticas: "Embora tenha aprendido bastante, senti que o tempo dedicado à exploração teórica das técnicas foi insuficiente. Algumas etapas ficaram confusas durante a implementação prática." Além disso, outros participantes mencionaram a falta de *feedbacks* imediato dos instrutores durante as atividades práticas, o que comprometeu o aprendizado de alguns alunos. A aluna do grupo 23 afirmou: "Faltou mais *feedbacks* imediato dos instrutores durante as atividades práticas. Algumas dúvidas ficaram sem resposta, o que atrasou o progresso."

Essas críticas indicam que, embora a aprendizagem ativa tenha sido eficaz para a maioria, a falta de apoio contínuo e a alta carga técnica das atividades podem ter dificultado o processo para alguns alunos.

5.4 Conclusão da análise quantitativa

A análise qualitativa realizada mostrou que a metodologia ativa aplicada no minicurso de Visão Computacional teve um impacto positivo no aprendizado dos alunos, com a maioria relatando melhorias significativas nas suas habilidades práticas e uma maior compreensão das técnicas abordadas. No entanto, também foram identificados desafios relacionados à carga teórica, suporte nas atividades práticas e equilíbrio nas responsabilidades do grupo. Os participantes reconhecem o valor do aprendizado para sua formação acadêmica e profissional, principalmente nas áreas de inteligência artificial e visão computacional, embora haja um desejo de mais profundidade em alguns aspectos do conteúdo.

A combinação de atividades práticas e discussões em grupo emergiu como o principal ponto forte da abordagem, mas a necessidade de um suporte mais equilibrado e material didático mais detalhado também foi um ponto importante para aprimoramentos futuros.

6 CONCLUSÃO

Este estudo evidenciou a eficácia da metodologia ativa de ensino na promoção de um aprendizado significativo no minicurso de Visão Computacional, ao integrar teoria e prática de maneira colaborativa e interativa. Ao envolver os alunos ativamente em atividades práticas, como a implementação e teste das técnicas de *Cascade Classifier* e *Histogram of Oriented Gradients*, o curso conseguiu fortalecer a compreensão dos conceitos, permitindo que os alunos aplicassem diretamente os conhecimentos adquiridos em um contexto real. Os resultados das análises quantitativas confirmaram a melhoria no desempenho dos participantes, com um aumento nas notas entre o pré e o pós-teste, demonstrando que a metodologia ativa contribuiu para o avanço do conhecimento na área.

Além disso, a análise qualitativa revelou uma percepção positiva por parte dos alunos em relação ao impacto da metodologia no

desenvolvimento de suas habilidades práticas e na compreensão dos desafios da visão computacional. A maioria dos participantes reconheceu a importância da abordagem prática, destacando o valor de poder experimentar diretamente as técnicas de detecção e extração de características, o que proporcionou uma aprendizagem mais aplicada e concreta.

Entretanto, também foram identificados aspectos que podem ser aprimorados para otimizar a experiência de aprendizagem. A carga teórica, embora essencial, foi apontada como um desafio para alguns alunos, que sugeriram uma distribuição mais equilibrada entre teoria e prática.

Portanto, os resultados deste estudo reafirmam a importância de adaptar as metodologias de ensino às necessidades dos alunos, buscando um equilíbrio entre teoria, prática e suporte contínuo durante o processo de aprendizagem. O uso de metodologias ativas, como a aplicada neste minicurso, tem o potencial de melhorar a compreensão de áreas avançadas da computação, como a inteligência artificial e a visão computacional, preparando os estudantes de forma mais eficaz para os desafios do mercado de trabalho. A continuidade dos ajustes propostos, aliados à inovação pedagógica, pode ampliar ainda mais os benefícios dessa abordagem, tornando-a uma ferramenta poderosa na formação de profissionais altamente capacitados e aptos a atuar em um campo tecnológico em constante evolução.

6.1 Limitações do trabalho

Este estudo apresenta algumas limitações que devem ser consideradas. Em primeiro lugar, o tamanho da amostra foi relativamente pequeno, com apenas 26 participantes, todos do curso de Engenharia de Software. Uma amostra maior e mais diversificada, incluindo estudantes de diferentes áreas e níveis de conhecimento, poderia fornecer uma visão mais abrangente da eficácia da metodologia. Além disso, a duração do curso foi de apenas 20 horas, o que limitou a profundidade da exploração dos tópicos. Para resolver essas questões, futuras edições do minicurso serão estendidas para um período mais longo, permitindo uma abordagem mais detalhada dos conceitos teóricos e práticos, e abranger um público mais amplo.

Outra limitação foi a ocorrência de dificuldades técnicas durante a implementação dos algoritmos, especialmente com o uso de ferramentas como o Google Colab e bibliotecas como o OpenCV. Para mitigar esse problema, planeja-se fornecer tutoriais mais detalhados e suporte técnico contínuo durante as atividades práticas. Adicionalmente, o curso focou principalmente nas técnicas de *Cascade Classifier* e HOG, o que limitou a diversidade de abordagens. No futuro, pretende-se incluir outras técnicas de visão computacional, como redes neurais convolucionais (CNNs) e métodos de segmentação de imagens, para enriquecer o conteúdo e proporcionar uma visão mais ampla e atualizada da área.

7 AGRADECIMENTOS

Este artigo é resultado do projeto de pesquisa e desenvolvimento ARANOUÁ financiado pela Samsung Eletrônica da Amazônia Ltda nos termos da Lei Federal nº 8.387/1991, de acordo com o art. 21 do Decreto nº 10.521/2020. Agradecemos, também, ao Campus Manaus Zona Leste do Instituto Federal do Amazonas (IFAM) pelos incentivos para a realização deste trabalho.

Referências

- [1] Yasunari Matsuzaka and Ryu Yashiro. Ai-based computer vision techniques and expert systems. *AI*, 4(1):289–302, 2023.
- [2] Eduardo D Agostinho and Alex Fabiano Bueno. A utilização de visão computacional em atividades cotidianas. *Universidade Federal de Santa Catarina*, 2020.
- [3] Serge Belongie, Jitendra Malik, and Jan Puzicha. Matching shapes. volume 1, pages 454–461 vol.1, 02 2001. ISBN 0-7695-1143-0. doi: 10.1109/ICCV.2001.937552.
- [4] Alexandre Biazi Guarizzo, Ana Maria Rosas da Silva, Andréia Freitas de Araújo, Gilmara Conceição dos Santos, Sandra de Oliveira Botelho, Suzeanny Magna da Silva Pereira, Tatiane do Rosário dos Santos Pereira, and Ziza Silva Pinho Woodcock. Metodologias de aprendizagem ativa: uma mudança de paradigma no ensino. *Caderno Pedagógico*, 21(5):e4186–e4186, 2024.
- [5] E Roy Davies. *Computer and machine vision: theory, algorithms, practicalities*. Academic Press, 2012.
- [6] QiuHong Ke, Jun Liu, Mohammed Bennamoun, Senjian An, Ferdous Sohel, and Farid Boussaid. Chapter 5 - computer vision for human-machine interaction. In Marco Leo and Giovanni Maria Farinella, editors, *Computer Vision for Assistive Healthcare*, Computer Vision and Pattern Recognition, pages 127–145. Academic Press, 2018. ISBN 978-0-12-813445-0. doi: <https://doi.org/10.1016/B978-0-12-813445-0.00005-8>. URL <https://www.sciencedirect.com/science/article/pii/B9780128134450000058>.
- [7] Jaskirat Kaur and Williamjeet Singh. Tools, techniques, datasets and application areas for object detection in an image: a review. *Multimedia Tools and Applications*, 81(27):38297–38351, 2022.
- [8] Chiranjit Lal Chowdhary, G Thippa Reddy, and BD Parameshachari. *Computer Vision and Recognition Systems: Research Innovations and Trends*. Apple Academic Press, 2022.
- [9] Suman Paneru and Idris Jeelani. Computer vision applications in construction: Current state, opportunities & challenges. *Automation in Construction*, 132: 103940, 2021.
- [10] Isha Gupta and Deepti Prit Kaur. Fpga based feature extraction in real time computer vision-a comprehensive survey. In *2022 International Conference on Signal and Information Processing (ICoSIP)*, pages 1–7. IEEE, 2022.
- [11] Friday Ugbebor, Olushola O Aina, and John O Ugbebor. Computer vision applications for smes in retail and manufacturing to automate quality control and inventory management processes: Artificial intelligence/machine learning enhancements. *Journal of Artificial Intelligence General science (JAIGS)* ISSN: 3006-4023, 5(1):460–500, 2024.
- [12] Paul Viola and Michael Jones. Rapid object detection using a boosted cascade of simple features. In *Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. CVPR 2001*, volume 1, pages I–I. Ieee, 2001.
- [13] Wen-Chang Cheng and Ding-Mao Jhan. A cascade classifier using adaboost algorithm and support vector machine for pedestrian detection. In *2011 IEEE International Conference on Systems, Man, and Cybernetics*, pages 1430–1435. IEEE, 2011.
- [14] Ratna Yustiawati, Nyayu Latifah Husni, Evelina Evelina, Sabil Rasyad, Iskandar Lutfi, Ade Silvia, Niksen Alfarizal, and Adella Rialita. Analyzing of different features using haar cascade classifier. In *2018 International Conference on Electrical Engineering and Computer Science (ICECOS)*, pages 129–134. IEEE, 2018.
- [15] Navneet Dalai and Bill Triggs. Histograms of oriented gradients for human detection. In *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*, volume 1, pages 886–893. Ieee, 2005.
- [16] Carlo Tomasi. Histograms of oriented gradients. *Computer Vision Sampler*, pages 1–6, 2012.
- [17] Dorlivete Moreira Shitsuka, Adriana S Pereira, Ricardo Shitsuka, and Claudio Boghi. Aprendizagem ativa de programação em turmas de engenharia: uma pesquisa-ação. *Research, Society and Development*, 8(3):36, 2019.
- [18] Simone Bello Kaminski Aires, Joao Paulo Aires, Maria João Pereira, and Luís M Alves. Aplicando uma metodologia de aprendizagem colaborativa no ensino de programação. *A Plurivaléncia da Engenharia da Computação e seu Amplo Campo de Aplicação*, pages 60–69, 2021.