

Aplicação e Análise de Algoritmos de Rastreamento Visual para Detecção de Bola em Partidas de Voleibol

Leandro Natálio F. Batista¹, Carlos Estevão B. Sousa¹, Cleidson S. de Santana¹, Carlos Eduardo S. de Maria¹, Felipe G. dos Santos¹, Renê Douglas N. de Moraes¹

¹Instituto Federal do Piauí (IFPI) – Campus Corrente
Rua Projetada 06, nº 380, Nova Corrente - CEP: 64.980-000 – Brazil

leandronatalio.dev@gmail.com, {carlos.sousa, cleidson.santana, carlos.soares, felipe.santos, rene.morais}@ifpi.edu.br

Abstract. *The use of Computer Vision has revolutionized sports analysis. In the context of volleyball, ball tracking presents challenges due to its size, speed, and occlusions. Given this, this study aims to evaluate tracking algorithms, including CSRT, MIL, TLD, MedianFlow, and Boosting, as well as train a YOLO model for ball detection. The analysis was conducted based on metrics such as IoU, FPS, and Mean Tracking Error. The methodology involved testing on videos of professional matches and controlled environments. The results indicate that controlled conditions favor superior performance, providing support for the development of systems to assist refereeing and sports analysis.*

Resumo. *O uso da Visão Computacional tem revolucionado a análise esportiva. No contexto do voleibol, o rastreamento da bola apresenta desafios devido ao seu tamanho, velocidade e oclusões. Diante disso, este trabalho objetiva avaliar algoritmos de rastreamento, incluindo CSRT, MIL, TLD, MedianFlow e Boosting, além de treinar um modelo YOLO para a detecção da bola. A análise foi conduzida com base em métricas como IoU, FPS e Erro Médio de Rastreamento. A metodologia adotou testes em vídeos de partidas profissionais e em ambientes controlados. Os resultados indicam que condições controladas favorecem um desempenho superior, fornecendo subsídios para o desenvolvimento de sistemas de apoio à arbitragem e à análise esportiva.*

1. Introdução

Os avanços tecnológicos têm desempenhado um papel crucial na modernização dos esportes, especialmente com a aplicação de técnicas de Visão Computacional (*Computer Vision* - CV). Esta área da ciência busca desenvolver métodos para interpretar informações visuais de maneira automatizada, em esportes engloba uma vasta gama de aplicações, como a análise detalhada de jogadas e a identificação de eventos com base no desempenho de atletas e equipes [Naik et al. 2022]. Além de transformar a experiência de assistir e analisar esportes, essas inovações contribuem para a melhoria de processos internos, como o suporte à tomada de decisões por árbitros e treinadores.

Entre os esportes que podem se beneficiar de inovações tecnológicas, o voleibol é frequentemente destacado devido à sua alta dinâmica e à complexidade das interações entre jogadores e bola. O rastreamento automatizado da bola, por exemplo, apresenta desafios significativos, considerando as movimentações rápidas e as constantes mudanças

na trajetória do objeto. Além disso, conforme [Han et al. 2024], características como a velocidade do jogo, o tamanho reduzido da bola e as oclusões frequentes causadas pelos jogadores tornam a aplicação de técnicas tradicionais de detecção e acompanhamento mais complexa.

Diante dos desafios inerentes ao rastreamento da bola no voleibol, o Rastreamento Visual de Objetos (*Visual Object Tracking* – VOT) emerge como uma abordagem essencial dentro da CV, dedicada a estimar a trajetória e o estado de um alvo ao longo de uma sequência de imagens [Javed et al. 2022]. O VOT pode ser aplicado tanto ao rastreamento de um único objeto (*Object Tracking* – OT) quanto ao de múltiplos objetos (*Multiple Object Tracking* – MOT), desempenhando um papel central na interpretação automatizada de cenários dinâmicos [Nunes 2023].

Tecnologias como chips destacam-se na coleta de dados específicos como velocidade e aceleração para rastreamento pontual [Ghosh et al. 2023], mas possuem limitações ao não capturarem o contexto global do jogo, incluindo posicionamento coletivo e interações entre jogadores. Em contraste, a CV oferece uma solução abrangente, registrando dinâmicas do jogo em múltiplos níveis [Ghosh et al. 2023]. Embora exija alto investimento inicial e infraestrutura robusta, permite análise contextualizada de movimentos e estratégias.

Dessarte, torna-se necessário avaliar como diferentes abordagens de OT podem lidar com as complexidades de uma partida de vôlei, analisando algoritmos clássicos e técnicas de Aprendizado Profundo (*Deep Learning* - DL) para aprimorar a detecção e o rastreamento da bola em tempo real. O objetivo deste trabalho é avaliar o desempenho de algoritmos de rastreamento visual, identificando as abordagens mais adequadas para a análise de partidas, a partir do rastreio da bola, considerando critérios como precisão, capacidade de adaptação e obtenção de informações detalhadas em tempo real.

2. Fundamentação Teórica

Pesquisas recentes avaliam algoritmos de VOT em diversos cenários. [Brdjanin et al. 2020] analisaram rastreadores da OpenCV [Bradski 2000] usando OTB-100 [Wu et al. 2013], destacando MIL [Babenko et al. 2010] e *Boosting* [Freund et al. 1996] pela taxa de sucesso, enquanto MOSSE [Bolme et al. 2010] e *MedianFlow* [Kalal et al. 2010] se sobressaíram em velocidade. O CSRT [Lukezic et al. 2017] mostrou alta precisão, com baixo desvio da *ground truth*, ou seja, a posição real de referência usada para avaliar a precisão dos rastreadores. Embora não específico para esportes, o estudo oferece contribuições relevantes.

[Gudauskas and Matusėvičius 2021] investigaram MOT no *goalball*, esporte paralímpico desenvolvido para pessoas com deficiência visual, no qual os jogadores, utilizando vendas nos olhos, tentam arremessar uma bola com guizos sonoros no gol adversário enquanto se orientam pelo som. Foram comparados o KCF [Henriques et al. 2014], CSR-DCF, MOSSE e TLD [Kalal et al. 2011] com redes neurais, concluindo que métodos clássicos ainda são competitivos, com MOSSE sendo rápido e KCF preciso em certos casos. Os autores sugerem que combinar técnicas tradicionais e modernas pode melhorar a robustez e a eficiência no rastreamento esportivo.

[Huang 2023] propôs uma adaptação do YOLOv4 para prever e analisar trajetórias de voleibol em vídeos. A estrutura GE-YOLO utiliza um YOLOv4 pré-treinado para iden-

tificar regiões com alta confiança e incorpora camadas de convolução gráfica para agregar características profundas, capturando a dinâmica do movimento do vôlei. Uma nova função de perda, modelando a área alvo com uma distribuição gaussiana, foi introduzida para melhorar a detecção de bolas pequenas e suas variações de escala. Os resultados demonstraram melhorias na precisão da detecção e no tratamento de oclusões.

Em contraste com os trabalhos focados em algoritmos de rastreamento, [Silva 2021] apresenta uma perspectiva aplicada sobre o uso da tecnologia na análise de desempenho no voleibol. O estudo enfatiza a importância de ferramentas tecnológicas para otimizar resultados e aprimorar o desenvolvimento dos atletas. A pesquisa discute fatores críticos para a adoção de tecnologias, como custo, facilidade de uso e confiabilidade, e destaca o valor da coleta de dados para uma tomada de decisão mais precisa pela equipe técnica, impactando as decisões táticas durante os jogos.

2.1. Rastreamento *Online* e Rastreamento *Offline*

O rastreamento de objetos pode ser realizado, conforme [Luo et al. 2021], em dois paradigmas principais: rastreamento *online* e rastreamento *offline*, cada um com vantagens e desvantagens, dependendo da aplicação e das restrições do sistema.

No rastreamento *online*, as decisões são tomadas em tempo real, com base nas informações disponíveis até o momento atual [Liu and Caesar 2023]. Esse método é amplamente utilizado em sistemas que exigem respostas imediatas, como veículos autônomos e videomonitoramento [Zhihui and Sijing 2021]. Sua principal vantagem é a baixa latência, permitindo interação em tempo real, mas pode ser limitado em precisão por não utilizar informações futuras.

Já o rastreamento *offline* analisa os dados de forma retrospectiva, utilizando todas as informações disponíveis para gerar resultados mais precisos [Fu et al. 2024]. É comum em aplicações como produção cinematográfica e análises esportivas [Yardimci and Şimşek Tekerek 2022], onde a precisão é priorizada. No entanto, sua dependência de processamento prévio limita o uso em cenários de tempo real.

2.2. Desafios no Rastreamento de Objetos

O VOT é crucial em diversas aplicações de CV, como vigilância, monitoramento de tráfego, análise esportiva e interação homem-máquina. No entanto, a tarefa enfrenta desafios como oclusão, variação de iluminação, mudança de aparência e sobreposição de objetos, que podem prejudicar a precisão e robustez dos algoritmos.

A oclusão, que ocorre quando um objeto é parcial ou totalmente coberto por outro [Bashar et al. 2022], leva a trocas de ID e fragmentação de trajetórias [Luo et al. 2021], sendo crítica a recuperação pós-occlusão. Variações de iluminação, devido a mudanças na luz natural ou artificial, afetam a aparência dos objetos [Chen et al. 2022], exigindo adaptação dos algoritmos para manter a continuidade do rastreamento [Liu et al. 2020].

Objetos frequentemente mudam de aparência durante o movimento devido a velocidade, iluminação, perspectiva e deformações [Ali et al. 2016], dificultando a identificação e demandando algoritmos com adaptação dinâmica [Liu et al. 2020]. Em ambientes densos, a sobreposição de objetos, especialmente com características visuais similares, causa confusão no rastreamento [Chen et al. 2022], sendo a complexidade acentuada pela movimentação dinâmica e variações de iluminação.

3. Metodologia

A metodologia adotada nesta pesquisa está estruturada de forma sistemática, conforme apresentada na Figura 1, combinando revisão bibliográfica, coleta e preparação de dados, aplicação de algoritmos, avaliação experimental e execução de testes.




Figura 1. Fluxo metodológico.

O percurso metodológico, ilustrado na Figura 1, é iniciado com a revisão da literatura, que busca identificar as principais técnicas de rastreamento utilizadas em aplicações esportivas, com foco no vôlei. Os conjuntos de dados disponíveis não atendiam de forma satisfatória às necessidades deste projeto, especialmente na detecção de bolas de vôlei em cenários variados. Diante disso, foi desenvolvido um conjunto de imagens próprio, alinhado ao ângulo de visão e à perspectiva específicos do projeto. A inclusão de desafios, como fundos densamente povoados, garante maior representatividade e adequação às condições reais do cenário de aplicação.

Para a construção desse conjunto, todos os vídeos utilizados foram obtidos a partir de conteúdos disponíveis publicamente no YouTube®, mais especificamente do canal [Volleyball Playoffs 2024]. A escolha dessa plataforma se justifica pelo amplo acesso a conteúdos diversificados e pela possibilidade de coleta de vídeos sob diferentes condições de filmagem, contribuindo para a variabilidade e robustez da base de dados.

O conjunto de imagens elaborado reúne 5.209 imagens extraídas dos vídeos, organizadas em formato compatível com o YOLO em sua versão 8 [Jocher et al. 2023]. O *dataset* foi dividido em três partes principais, seguindo a divisão de 80% para treinamento, 10% para validação e 10% para teste. Todas as imagens possuem características uniformes, como resolução de 1920×1080 px. Alguns exemplos de imagens do conjunto, com suas respectivas caixas delimitadoras, são apresentados na Figura 2.




Figura 2. Imagens do *dataset*.

Adicionalmente às imagens exemplificadas na Figura 2, foram realizadas gravações em ambiente controlado para avaliar como fatores específicos, como a cor da bola, podem influenciar o processo de rastreamento. As bolas utilizadas possuem as cores

azul, laranja e verde, permitindo analisar o impacto de diferentes tonalidades no desempenho dos algoritmos. Na Figura 3, são ilustrados exemplos de imagens obtidas das gravações realizadas em ambiente controlado.




Figura 3. Imagens dos vídeos de ambiente controlado.

Esse conjunto conta com aproximadamente 2.099 imagens extraídas de vídeos gravados com *smartphones* em resoluções de $1920 \times 1080 px$, Full HD, a 60 FPS, e $1280 \times 720 px$, HD, a 30 FPS. A aplicação dos algoritmos incluiu rastreadores clássicos disponíveis na biblioteca OpenCV, como CSRT, MIL, TLD, *Boosting* e *MedianFlow*, além do modelo customizado do YOLOv8, treinado com o conjunto de imagens elaborado neste trabalho. Esses são utilizados com seus parâmetros padrões, assegurando uniformidade na análise.

A avaliação dos algoritmos é conduzida com base na Interseção sobre União (*Intersection over Union* - IoU), o Erro Médio de Rastreamento (*Mean Tracking Error* - MTE) e a taxa de *Frames* por Segundo (*Frames Per Second* - FPS). Além disso, é realizada uma análise qualitativa para observar o comportamento dos algoritmos em situações reais de jogo, como oclusões e mudanças rápidas. Por fim, a execução de testes envolve a aplicação prática dos algoritmos em vídeos de partidas de vôlei, verificando sua eficácia.

4. Experimento e Resultados

Os vídeos utilizados para os testes são divididos em dois cenários: partidas profissionais e ambiente controlado. Os vídeos de partidas profissionais utilizados nos experimentos possuem as seguintes características. O primeiro vídeo, Vídeo 1, tem uma taxa de 30 FPS e resolução de $1280 \times 720 pixels$, enquanto o segundo vídeo, Vídeo 2, apresenta uma taxa de 60 FPS e resolução de $1920 \times 1080 pixels$.

Para os testes em ambiente controlado, são utilizados seis vídeos gravados especificamente para a avaliação dos rastreadores em condições mais previsíveis. Esses vídeos possuem diferentes cores de bola. Três vídeos têm uma taxa de 30 FPS e resolução de $1280 \times 720 pixels$, com bolas nas cores azul, laranja e verde, vídeos 1, 2 e 3, respectivamente. Outros três vídeos possuem uma taxa de 60 FPS e resolução de $1920 \times 1080 pixels$, também com bolas nas cores azul, laranja e verde, vídeos 4, 5 e 6, respectivamente.

4.1. Resultados da Interseção sobre União (*Intersection over Union* - IoU)

Nos gráficos da Figura 4, são apresentados os resultados da métrica IoU considerando apenas os 30 primeiros *frames*, pois, após esse ponto, as diferenças entre os rastreadores não variam significativamente. Esse comportamento se deve ao fato de que os algoritmos de rastreamento analisados eventualmente perdem a localização do alvo e não conseguem

realizar uma reidentificação eficaz nos quadros subsequentes, levando a uma degradação abrupta ou à estagnação dos valores da métrica IoU.




Figura 4. IoU dos rastreadores nos vídeos de partidas profissionais.

O algoritmo CSRT apresenta melhor desempenho, principalmente no vídeo de $1280 \times 720 px$, como é possível observar na Figura 4, porém esse desempenho ainda é insuficiente para garantir consistência, pois, mesmo sendo o melhor entre os avaliados, o rastreador perde rapidamente o objeto quando este aumenta bruscamente a velocidade ou se confunde com elementos do fundo. Em contraste, os vídeos amadores em ambientes controlados possuem fundos menos complexos e movimentos mais previsíveis. Nos gráficos da Figura 5 são ilustrados os melhores resultados para esses vídeos.

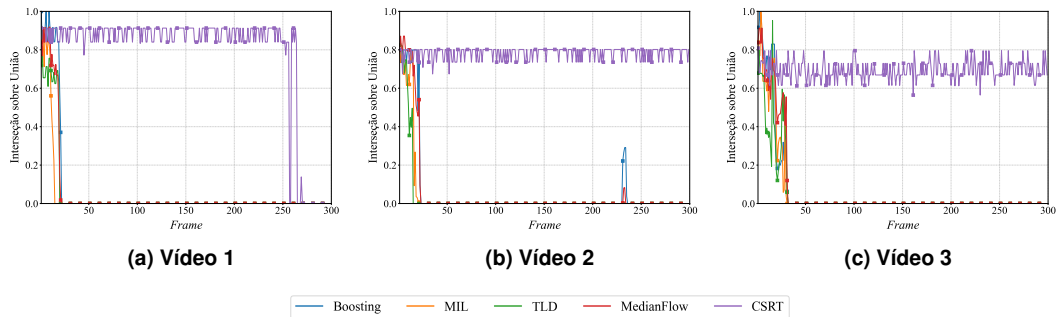


Figura 5. IoU dos rastreadores nos vídeos de ambiente controlado.

Como apresentado na Figura 5, nos vídeos amadores, o CSRT novamente apresenta um desempenho superior, mantendo IoU consistente na maioria dos casos, com precisão média de aproximadamente 0.9 no Vídeo 1 e 0.8 no Vídeo 2. Comparando os dois cenários, mesmo com velocidade moderada e menor poluição visual, é possível observar que os desafios persistem.

No contexto profissional, a velocidade elevada e a presença de elementos visuais concorrentes dificultam ainda mais o rastreamento, enquanto no ambiente controlado, embora com menor complexidade, limitações dos próprios algoritmos ainda comprometem a robustez do rastreo ao longo do tempo.

4.2. Resultados de Quadros por Segundo (*Frames Per Second - FPS*)

O FPS foi utilizado como métrica para avaliar o custo computacional dos rastreadores, representando uma forma simples de quantificar sua eficiência. Os resultados indicam

que rastreadores mais precisos tendem a ser mais lentos. Na Figura 6 são apresentadas as médias de FPS alcançadas pelos rastreadores em diferentes resoluções.




Figura 6. Desempenho em FPS dos rastreadores em diferentes resoluções.

Ao analisar a Figura 6, observa-se uma relação inversa entre precisão e velocidade. O CSRT, com maior IoU, prioriza robustez sobre velocidade. O *MedianFlow* oferece desempenho intermediário, enquanto o MIL mantém uma taxa consistente entre resoluções. Já o TLD e o *Boosting* apresentam desempenho inferior, com o *Boosting* destacando-se pela maior precisão.

Essa troca entre precisão e velocidade é crucial na escolha do algoritmo mais adequado para rastreamento em tempo real. Algoritmos mais robustos, como o CSRT e o *Boosting*, são mais indicados para cenários que exigem maior confiabilidade, enquanto os mais rápidos não demonstraram eficiência suficiente para tarefas complexas.

4.3. Erro Médio de Rastreamento (*Mean Tracking Error* - MTE)

Esta métrica quantifica a precisão do rastreamento, sendo que valores menores indicam um desempenho superior. A seguir, na Figura 7, é possível observar os resultados em vídeos profissionais.




Figura 7. Erro Médio de Rastreamento em vídeos de partidas profissionais.

Na Figura 7, podemos observar que o CSRT e o *Boosting* apresentam um desempenho intermediário, com valores entre 0.4 e 0.6, demonstrando dificuldades mesmo para os melhores rastreadores. Os demais rastreadores ficam em faixas semelhantes de erro. Na Figura 8, são apresentados os resultados referentes ao ambiente controlado, onde os rastreadores apresentaram menor taxa de erro.




Figura 8. Erro Médio de Rastreamento em vídeos de ambiente controlado.

Como ilustrado na Figura 8, o CSRT obteve o melhor desempenho, chegando a apresentar erro próximo a zero. Já o *Boosting* demonstra desempenho intermediário. O *MedianFlow* e MIL apresentaram maior instabilidade, comprometendo o rastreo. Estes resultados corroboram os desafios inerentes ao VOT em cenários dinâmicos. A sensibilidade do *MedianFlow* e do MIL a pequenas perturbações indica que esses algoritmos carecem de robustez em ambientes com alto grau de variabilidade. Em contraste, o desempenho do CSRT em condições controladas aponta que a incorporação de informações contextuais e mecanismos de confiança pode melhorar a resiliência do rastreamento.

5. Análise Visual

A análise visual concentra-se no ambiente controlado, representado pelo Vídeo 2, devido ao desempenho superior, em termos de MTE e IoU. Como ilustrado na Figura 9, os algoritmos conseguiram rastrear a bola de forma mais consistente em condições simplificadas.

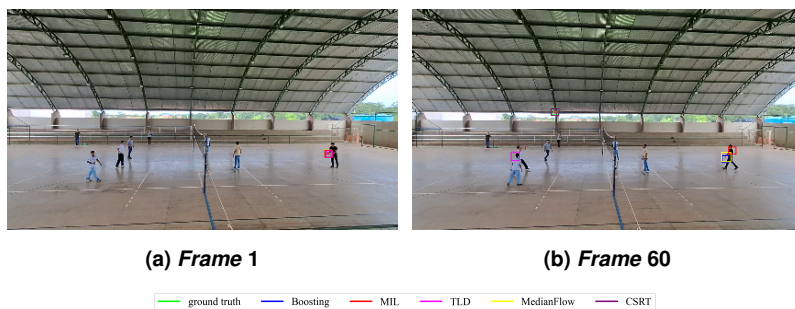


Figura 9. Análise visual do vídeo de cenário controlado.

No *Frame 1*, Subfigura 9a, todos os algoritmos posicionaram corretamente suas caixas delimitadoras. Contudo, apenas o CSRT manteve a precisão ao longo do tempo, enquanto os demais algoritmos demonstraram limitações, como perda do objeto ou fixação em outros elementos, como ilustrado na Subfigura 9b, *Frame 60*. A estagnação do rastreo-

amento ocorreu principalmente em situações de oclusão, sendo que a maioria dos rastreadores não conseguiu retomar o acompanhamento do objeto após essas interrupções.

6. Resultados do YOLOv8

O modelo YOLOv8 foi treinado até que os indicadores de desempenho no conjunto de validação, apresentados na Figura 10, se estabilizassem, ou seja, deixassem de apresentar melhorias significativas com o avanço das épocas, indicando que o modelo havia atingido seu melhor desempenho possível naquele cenário.

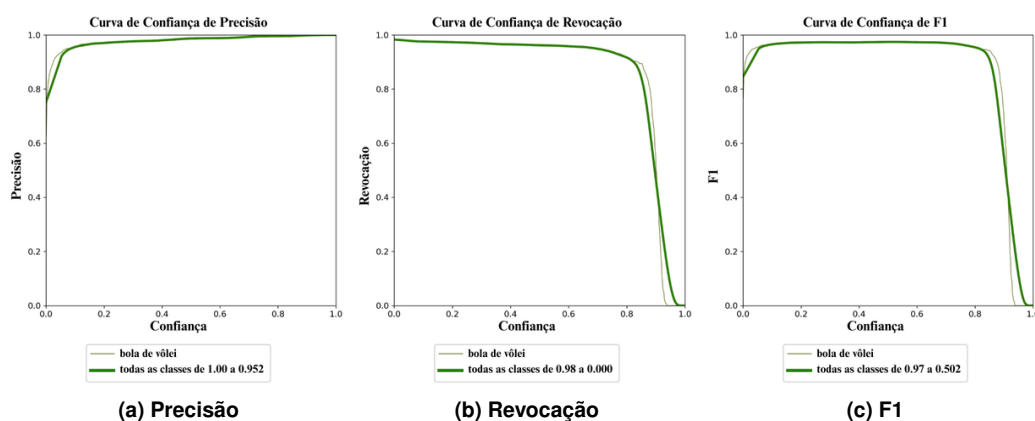


Figura 10. Curvas de Precisão, Revocação e F1.

As curvas apresentadas na Figura 10 evidenciam o desempenho do modelo. A Subfigura 10a mostra que o modelo obteve precisão máxima de 1.00, atingida em um limiar de 0.952, o que indica elevada confiabilidade nas predições. Já a Revocação, apresentada na Subfigura 10b, alcançou valor máximo de 0.98 em limiares próximos a zero, reduzindo-se acentuadamente em valores mais altos, o que evidencia um *trade-off* entre confiança e cobertura das detecções, ou seja, aumentar o limiar eleva a precisão, mas reduz a revocação. Por fim, a curva F1, mostrada na Subfigura 10c, alcançou valor máximo de 0.97 em um limiar intermediário de 0.502, demonstrando bom equilíbrio entre precisão e revocação na configuração ótima.

Apesar do resultado alcançado, o modelo apresentou limitações significativas ao ser aplicado para VOT. Entre os problemas observados, destaca-se a dificuldade em manter a continuidade do rastreamento, resultando em trajetórias inconsistentes. Além disso, ocorreram trocas frequentes de IDs, como ilustrado na Figura 11, indicando falhas na preservação da identidade dos objetos rastreados.




Figura 11. Troca de ID ao longo dos frames.

Na Figura 11, é possível observar que, no *Frame* 100, Subfigura 11a, o objeto identificado com o ID 8 é rastreado, mas no *Frame* 1000, Subfigura 11b, o mesmo objeto é identificado como ID 114, evidenciando uma troca de identificador ao longo da sequência. Esse tipo de variação pode ocorrer em decorrência de interrupções momentâneas na detecção ou mudanças na aparência do objeto, sendo uma limitação comum em abordagens baseadas apenas em detecções quadro a quadro, sem mecanismos de associação temporal mais avançados. Adicionalmente, o tempo de execução elevado inviabiliza o uso do modelo em aplicações de tempo real.

7. Considerações Finais

Os resultados obtidos evidenciaram que o algoritmo CSRT apresentou o melhor desempenho geral, destacando-se em termos de precisão (IoU) e estabilidade no rastreamento, especialmente em cenários controlados. No entanto, mesmo o CSRT demonstrou limitações significativas em partidas profissionais, onde a maior complexidade do ambiente impactou negativamente sua robustez e consistência. Outros algoritmos, como *Boosting* e *MedianFlow*, apresentaram desempenhos intermediários, enquanto TLD obteve os piores resultados, com baixa precisão e maior suscetibilidade a falhas.

Esses achados concordam com os apresentados em [Brdjanin et al. 2020] e em [Gudauskas and Matusevičius 2021], especialmente no que diz respeito ao CSRT. No entanto, alguns rastreadores apresentaram resultados inferiores para objetos menores do que os alvos analisados nesses trabalhos, corroborando a observação de que seu desempenho é particularmente afetado em casos com reduzida resolução ou baixa visibilidade do alvo.

A análise revelou uma troca entre precisão e eficiência computacional. Algoritmos mais precisos, como o CSRT, tendem a ser mais lentos, enquanto os mais rápidos, como o MOSSE, apresentam desempenho inferior. Esse equilíbrio entre precisão e velocidade é um fator crítico a ser considerado no desenvolvimento de sistemas em tempo real, como os destinados à arbitragem e análise de desempenho.

Os resultados demonstram que rastreadores com baixo desempenho em termos de precisão não devem ser avaliados exclusivamente com base na velocidade. Embora o *MedianFlow* e MIL sejam mais rápidos, sua baixa precisão compromete sua utilidade em aplicações que exigem rastreamento confiável. Por outro lado, o CSRT destaca-se por oferecer a maior precisão, ao mesmo tempo em que mantém uma taxa de FPS moderada, demonstrando que é possível alcançar um equilíbrio entre precisão e velocidade, mesmo com alguma perda em desempenho.

Acrescenta-se que os resultados obtidos com o modelo treinado do YOLO, embora promissores para a detecção, ainda necessitam de melhorias para que seja possível realizar o rastreamento de modo mais confiável. Outro problema identificado é a generalização do modelo, que requer uma quantidade maior de amostras para um treinamento mais eficaz. Apesar de se tratar de uma forma mais simplificada do uso do YOLO em comparação com a realizada por [Huang 2023], esses resultados evidenciam que o uso de DL aprimora o processo de rastreamento, ainda que a um custo consideravelmente superior de recursos.

Os desafios enfrentados pelos algoritmos em cenários profissionais reforçam a necessidade de soluções mais adaptativas e resilientes, capazes de lidar com situações dinâmicas e imprevisíveis. Fatores como oclusões frequentes, variações de iluminação

e a alta velocidade da bola destacam as limitações dos algoritmos clássicos, indicando que abordagens baseadas em DL podem oferecer maior capacidade de generalização e robustez em ambientes complexos.

Referências

- Ali, A., Jalil, A., Niu, J., Zhao, X., Rathore, S., Ahmed, J., and Aksam Iftikhar, M. (2016). Visual object tracking—classical and contemporary approaches. *Frontiers of Computer Science*, 10:167–188.
- Babenko, B., Yang, M.-H., and Belongie, S. (2010). Robust object tracking with on-line multiple instance learning. *IEEE transactions on pattern analysis and machine intelligence*, 33(8):1619–1632.
- Bashar, M., Islam, S., Hussain, K. K., Hasan, M. B., Rahman, A., and Kabir, M. H. (2022). Multiple object tracking in recent times: A literature review. *arXiv preprint arXiv:2209.04796*.
- Bolme, D. S., Beveridge, J. R., Draper, B. A., and Lui, Y. M. (2010). Visual object tracking using adaptive correlation filters. *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 2544–2550.
- Bradski, G. (2000). The OpenCV Library. *Dr. Dobb's Journal of Software Tools*.
- Brdjanin, A., Dardagan, N., Dzigal, D., and Akagic, A. (2020). Single object trackers in opencv: A benchmark. In *2020 International Conference on Innovations in Intelligent Systems and Applications (INISTA)*, pages 1–6, Novi Sad, Serbia. IEEE.
- Chen, F., Wang, X., Zhao, Y., Lv, S., and Niu, X. (2022). Visual object tracking: A survey. *Computer Vision and Image Understanding*, 222:103508.
- Freund, Y., Schapire, R. E., et al. (1996). Experiments with a new boosting algorithm. In *icml*, volume 96, pages 148–156. Citeseer.
- Fu, Y., Qin, P., Zhang, J., and Lu, Z. (2024). Joint ai inference and target tracking at network edge: A hybrid offline-online design for uav-enabled network. *IEEE Transactions on Wireless Communications*.
- Ghosh, I., Ramasamy Ramamurthy, S., Chakma, A., and Roy, N. (2023). Sports analytics review: Artificial intelligence applications, emerging technologies, and algorithmic perspective. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 13(5):e1496.
- Gudauskas, J. and Matusevičius, Ž. (2021). Multiple object tracking for video-based sports analysis. In *CEUR workshop proceedings: IVUS 2021: Information society and university studies 2021: Proceedings of the 26th international conference on information society and university studies (IVUS 2021)*, volume 2915, pages 1–10, Kaunas, Lithuania. CEUR-WS.
- Han, X., Wang, Q., and Wang, Y. (2024). Ball tracking based on multiscale feature enhancement and cooperative trajectory matching. *Applied Sciences*, 14(4):1376.
- Henriques, J. F., Caseiro, R., Martins, P., and Batista, J. (2014). High-speed tracking with kernelized correlation filters. *IEEE transactions on pattern analysis and machine intelligence*, 37(3):583–596.

- Huang, G. (2023). An effective volleyball trajectory estimation and analysis method with embedded graph convolution. *International Journal of Distributed Systems and Technologies (IJDST)*, 14(2):1–13.
- Javed, S., Danelljan, M., Khan, F. S., Khan, M. H., Felsberg, M., and Matas, J. (2022). Visual object tracking with discriminative filters and siamese networks: a survey and outlook. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(5):6552–6574.
- Jocher, G., Chaurasia, A., and Qiu, J. (2023). Ultralytics yolov8.
- Kalal, Z., Mikolajczyk, K., and Matas, J. (2010). Forward-backward error: Automatic detection of tracking failures. In *2010 20th International Conference on Pattern Recognition*, pages 2756–2759, Istanbul, Turkey. IEEE.
- Kalal, Z., Mikolajczyk, K., and Matas, J. (2011). Tracking-learning-detection. *IEEE transactions on pattern analysis and machine intelligence*, 34(7):1409–1422.
- Liu, S., Liu, D., Srivastava, G., Połap, D., and Woźniak, M. (2020). Overview of correlation filter based algorithms in object tracking. complex intell syst.
- Liu, X. and Caesar, H. (2023). Offline tracking with object permanence. *arXiv.org*, abs/2310.01288.
- Lukezic, A., Vojir, T., Cehovin Zajc, L., Matas, J., and Kristan, M. (2017). Discriminative correlation filter with channel and spatial reliability. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 6309–6318, Honolulu, Hawaii, USA. IEEE.
- Luo, W., Xing, J., Milan, A., Zhang, X., Liu, W., and Kim, T.-K. (2021). Multiple object tracking: A literature review. *Artificial intelligence*, 293:103448.
- Naik, B. T., Hashmi, M. F., and Bokde, N. D. (2022). A comprehensive review of computer vision in sports: Open issues, future trends and research directions. *Applied Sciences*, 12(9):4429.
- Nunes, V. d. S. (2023). Tópicos em visão computacional: uma revisão sistemática com aplicações em economia 4.0.
- Silva, R. B. d. (2021). Desenvolvimento de tecnologia de informação e comunicação (tic) para análise instantânea de desempenho de voleibol.
- Volleybal Playoffs (2024). Canal do YouTube: VolleybalPlayoffs. <https://www.youtube.com/@volleybalplayoffs>. Acesso em: 9 nov. 2024.
- Wu, Y., Lim, J., and Yang, M.-H. (2013). Online object tracking: A benchmark. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 2411–2418, Portland, Oregon, USA. IEEE, IEEE.
- Yardimci, O. and Şimşek Tekerek, A. (2022). Performance comparison of online and offline tracking algorithms. In *Signal Processing, Sensor/Information Fusion, and Target Recognition XXXI*, volume 12096, pages 1209604–1209604, Orlando, Florida, USA. SPIE.
- Zhihui, S. and Sijing, C. (2021). Offline method-based online tracking method and apparatus, computer device, and storage medium.