

Visão Computacional no Esporte: Avaliação de Algoritmos Clássicos para Rastreamento de Bola no 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. *Visual object tracking is a promising approach for applications in sports analysis. This study evaluates the performance of classical tracking algorithms, such as CSRT, KCF, MOSSE, MIL, TLD, MedianFlow, and Boosting, in the task of tracking the trajectory of a volleyball in video footage. Both professional match recordings and controlled environment videos were used. The applied metrics include IoU, FPS, and MTE. Among the algorithms, CSRT achieved the best performance in terms of accuracy, while MOSSE and KCF yielded the least satisfactory results. The findings of this study contribute to the development of applications aimed at supporting tactical and technical analysis in sports contexts.*

Resumo. *O rastreamento visual de objetos é uma abordagem promissora para aplicações em análise esportiva. Neste trabalho, é avaliado o desempenho de algoritmos clássicos de rastreamento, como CSRT, KCF, MOSSE, MIL, TLD, MedianFlow e Boosting, na tarefa de rastrear a trajetória da bola de voleibol em vídeos. Para isso, foram utilizados registros de partidas profissionais e gravações em ambientes controlados. As métricas aplicadas incluem a IoU, FPS e MTE. Dentre os algoritmos, o CSRT apresenta o melhor desempenho em termos de precisão, enquanto MOSSE e KCF obtêm os resultados menos satisfatórios. Os achados deste estudo contribuem para o desenvolvimento de aplicações voltadas ao apoio da análise tática e técnica no contexto esportivo.*

1. Introdução

O voleibol, esporte caracterizado por sua natureza dinâmica e pelas rápidas interações entre jogadores e bola, está entre aqueles que mais se beneficiam dos avanços tecnológicos. No entanto, o rastreamento da bola nesse contexto apresenta diversos desafios, como a alta velocidade de movimento, o tamanho reduzido do objeto e a frequente oclusão causada pelos jogadores, fatores que comprometem a eficácia de muitas abordagens tradicionais de detecção e acompanhamento [Han et al. 2024].

Diante desses desafios, o uso de tecnologias emergentes tem promovido transformações significativas, especialmente por meio da aplicação da Visão Computacional (*Computer Vision* - CV). Essa área busca desenvolver algoritmos capazes de interpretar automaticamente informações visuais, possibilitando a realização de tarefas complexas, como o reconhecimento de padrões, a análise de jogadas e a detecção de eventos [Naik et al. 2022].

Nesse contexto, a CV se apresenta como uma solução mais abrangente, capaz de interpretar, em tempo real, elementos estratégicos e espaciais do jogo por meio de algoritmos sofisticados. Embora sua implementação exija uma infraestrutura tecnológica robusta e investimentos significativos, os benefícios em termos de precisão e riqueza das informações obtidas justificam amplamente esses custos [Ghosh et al. 2023].

Entre as técnicas fundamentais da CV aplicadas ao voleibol, destaca-se o Rastreamento Visual de Objetos (*Visual Object Tracking – VOT*), que tem como objetivo a estimativa contínua da posição e do estado de alvos ao longo de sequências de imagens [Javed et al. 2022]. Essa técnica é particularmente relevante para o acompanhamento da bola durante as rápidas transições do jogo.

Além disso, outras abordagens têm sido exploradas, como o uso de sensores e dispositivos eletrônicos para a captura de dados específicos, por exemplo, velocidade e aceleração da bola. Apesar de contribuírem para a coleta de informações pontuais, essas soluções apresentam limitações importantes, sobretudo por não conseguirem captar o contexto tático mais amplo da partida, como a movimentação coordenada dos jogadores e suas interações em quadra [Ghosh et al. 2023].

Considerando esse panorama, torna-se pertinente investigar quais algoritmos de rastreamento são mais adequados para lidar com a complexidade do voleibol, especialmente no que se refere à detecção e acompanhamento em tempo real da bola e dos jogadores. O presente trabalho tem como objetivo avaliar o desempenho de algoritmos clássicos de rastreamento pela sua viabilidade para aplicações em tempo real, com foco em precisão, adaptabilidade e capacidade de fornecer informações relevantes para a análise automatizada de partidas esportivas por meio do rastreamento da bola.

2. Trabalhos Relacionados

Nos últimos anos, diversos estudos têm sido conduzidos com o objetivo de avaliar o desempenho de algoritmos de VOT em diferentes contextos. Entre essas iniciativas, destaca-se a avaliação realizada por [Brdjanin et al. 2020], que investigaram os rastreadores disponíveis na biblioteca OpenCV [Bradski 2000] utilizando o conjunto de dados OTB-100 [Wu et al. 2013]. Dentre os algoritmos avaliados, MIL [Babenko et al. 2010] e *Boosting* [Freund et al. 1996] apresentaram as maiores taxas de sucesso, enquanto MOSSE [Bolme et al. 2010] e *MedianFlow* [Kalal et al. 2010] se destacaram pela alta velocidade. O rastreador CSRT [Lukezic et al. 2017] demonstrou elevada precisão, com baixo desvio em relação ao *ground truth*, ou seja, à caixa delimitadora correta esperada. Apesar de não focar diretamente no contexto esportivo, o estudo fornece subsídios importantes para aplicações mais específicas.

[Gudauskas and Matusevičius 2021] investigaram técnicas de rastreio aplicadas à análise do *goalball*, esporte paralímpico praticado por pessoas com deficiência visual, em que os jogadores se orientam pelo som da bola para marcar gols. O trabalho comparou diferentes métodos de rastreamento, incluindo algoritmos clássicos, como *Boosting*, CSRDCF, KCF [Henriques et al. 2014], MOSSE e TLD [Kalal et al. 2011], além de abordagens baseadas em Redes Neurais Convolucionais (*Convolutional Neural Network - CNN*). Os resultados obtidos por [Gudauskas and Matusevičius 2021] demonstram que algoritmos clássicos ainda oferecem desempenho competitivo, com destaque para o MOSSE pela velocidade e o KCF pela precisão em determinados cenários. Além disso, os autores

sugerem que a combinação entre técnicas tradicionais e modernas pode representar uma abordagem promissora para melhorar a robustez e a eficiência do rastreamento em vídeos esportivos, enfrentando desafios como oclusões, variações de iluminação e mudanças na aparência dos objetos rastreados.

Dentre os avanços mais recentes no rastreamento visual aplicado a esportes, destaca-se o trabalho de [Han et al. 2024], que propuseram o modelo HMMATrack, voltado especificamente ao rastreamento de bolas em modalidades como futebol, basquete e voleibol. A proposta combina uma estratégia de amostragem heurística com um detector baseado em redes sem âncoras e um algoritmo de rastreamento colaborativo multiescalar. Tal abordagem visa superar desafios típicos do rastreamento de objetos pequenos, como a bola, que apresentam alta velocidade, oclusões frequentes e confusão com o fundo.

Diferentemente dos estudos citados, o presente trabalho concentra-se especificamente no contexto do voleibol, explorando a complexidade singular desse esporte em termos de dinâmica dos jogadores e movimentação da bola. Além disso, são avaliados algoritmos clássicos de rastreamento, devido à sua leveza computacional e potencial para aplicações em tempo real. O enfoque consiste em uma análise comparativa do desempenho desses métodos nesse cenário específico.

3. Desafios no Rastreamento Visual de Objetos - VOT

O VOT representa uma tarefa essencial em diversas áreas da Visão Computacional, como a vigilância automatizada, o controle de tráfego, a interação homem-máquina e a análise de jogos esportivos. Apesar de sua ampla aplicação, essa tarefa envolve uma série de obstáculos que dificultam a obtenção de resultados precisos e confiáveis. Entre os desafios mais recorrentes estão a oclusão, as variações na aparência dos objetos e a sobreposição entre alvos.

A oclusão, processo ilustrado na Figura 1, se refere à situação em que o objeto de interesse é parcial ou totalmente encoberto por outro no mesmo quadro, o que frequentemente leva à fragmentação da trajetória e à troca de identidade do objeto rastreado [Bashar et al. 2022, Luo et al. 2021]. Esse problema é especialmente relevante em ambientes com múltiplos alvos em movimento. A superação da oclusão exige estratégias de recuperação que combinem técnicas de predição e reconstrução, visando preservar a continuidade das trajetórias e melhorar a robustez do rastreamento [Bashar et al. 2022].




Figura 1. Oclusão.

Outro fator crítico é a mudança de aparência, representado na Figura 2, que ocorre quando o objeto sofre alterações visuais ao longo do tempo devido à velocidade, à variação da iluminação, a diferentes ângulos de visão ou até a deformações

[Ali et al. 2016]. Tais mudanças tornam mais difícil a identificação contínua do alvo, exigindo algoritmos adaptativos que consigam responder de forma eficaz às transformações visuais. A capacidade de adaptação dinâmica dos modelos é, portanto, essencial para garantir desempenho satisfatório em ambientes não controlados [Liu et al. 2020].



Figura 2. Exemplo de mudança de aparência. Adaptado de [Liu et al. 2020].

A confusão entre objetos, por sua vez, é um desafio frequente em cenas com alta densidade de elementos, como em jogos esportivos ou ambientes urbanos movimentados. Quando objetos com aparência semelhante se cruzam ou se aproximam, a distinção entre eles se torna mais difícil, comprometendo a precisão do rastreamento [Chen et al. 2022]. Essa situação é agravada por fatores como iluminação variável e movimentação imprevisível, que exigem algoritmos robustos o suficiente para manter a integridade do rastreo.

4. Metodologia

A metodologia adotada nesta pesquisa está estruturada de forma sistemática, combinando revisão bibliográfica, coleta e preparação de dados, aplicação de algoritmos, avaliação experimental e execução de testes. O primeiro passo consiste na revisão de literatura, com o objetivo de identificar técnicas clássicas de rastreamento visual aplicadas ao contexto esportivo, com ênfase em partidas de vôlei. Como os conjuntos de dados existentes não atendiam adequadamente às exigências do estudo, especialmente no que diz respeito à detecção da bola em diferentes cenários, foi construída uma base própria de imagens, considerando o ângulo e a perspectiva específicos do projeto.

Esse conjunto de imagens é formado a partir de vídeos públicos extraídos do YouTube®, com foco no canal [Volleybal Playoffs 2024]. A escolha dessa plataforma se dá pela variedade de conteúdos e pelas diferentes condições de captação, contribuindo para a diversidade e representatividade do material. Foram extraídas 5.209 imagens padronizadas para resolução de $1920 \times 1080 px$. Exemplos de imagens do conjunto são apresentados na Figura 3.



(a) Exemplo 1

(b) Exemplo 2

Figura 3. Exemplos de imagens dos conjuntos.

Além das imagens obtidas de jogos profissionais, Subfigura 3a, foram realizadas gravações em ambiente controlado, Subfigura 3b, para investigar a influência da cor da bola sobre o desempenho dos algoritmos. As bolas utilizadas são azul, laranja e verde, totalizando cerca de 2.099 imagens obtidas de vídeos capturados com *smartphones*, em resoluções Full HD ($1920 \times 1080 \text{ px}$, 60 FPS) e HD ($1280 \times 720 \text{ px}$, 30 FPS). Ademais, a ausência de plateia nesse cenário contribui para a redução de interferências provenientes de fundos com alta densidade visual.

Nos testes, são aplicados os algoritmos tradicionais de rastreamento da biblioteca OpenCV, como CSRT, KCF, MOSSE, MIL, TLD, *Boosting* e *MedianFlow*. Os parâmetros utilizados são os padrões oferecidos pela biblioteca para garantir consistência nas análises. A avaliação considera métricas como Interseção sobre União (*Intersection over Union* - IoU), o Erro Médio de Rastreamento (*Mean Tracking Error* - MTE) e a taxa de Quadros por Segundo (*Frames Per Second* - FPS), complementadas por análises qualitativas em situações típicas de jogo, como oclusões e movimentos bruscos.

Consequente, os testes em vídeos de partidas reais permitem validar a eficácia dos algoritmos em cenários práticos, possibilitando identificar as abordagens mais apropriadas em termos de precisão, robustez e desempenho computacional.

5. Resultados

Os vídeos utilizados nos testes são organizados em dois grupos distintos: partidas profissionais e ambiente controlado. O primeiro grupo apresenta maior complexidade, com movimentações rápidas e fundos visualmente densos. O segundo grupo, por sua vez, foi gravado em condições controladas, com fundos simples e variáveis específicas, como a cor da bola, para facilitar a análise dos rastreadores.

No grupo de partidas profissionais, são utilizados dois vídeos, um com resolução de 1280×720 a 30 FPS, e outro com resolução de 1920×1080 a 60 FPS. Esses vídeos representam ambientes com elevada complexidade visual e dinâmica, incluindo múltiplos jogadores em movimento, mudanças frequentes de ângulo de câmera e variações de iluminação, o que impõe desafios adicionais aos algoritmos de rastreamento.

Já no ambiente controlado, são utilizados seis vídeos, todos voltados à análise do impacto de variáveis específicas. Três deles possuem resolução de 1280×720 a 30 FPS, sendo um com bola azul, outro com bola laranja e um terceiro com bola verde. Os outros três vídeos apresentam resolução de 1920×1080 a 60 FPS, com as mesmas variações de cor da bola: azul, laranja e verde, respectivamente.

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

Os algoritmos demonstram desempenho insatisfatório em vídeos profissionais devido à complexidade dos fundos, à presença de plateia e às rápidas mudanças de trajetória dos objetos. Nos gráficos da Figura 4 são apresentados os resultados da métrica IoU considerando apenas os 60 primeiros *frames*. Essa limitação se deve à interrupção do rastreamento após esse ponto, causada pela incapacidade dos algoritmos de manter ou recuperar a trajetória do alvo ao longo do tempo.

O rastreamento, nesse cenário, mostrou-se um grande desafio, especialmente devido à velocidade com que a bola se desloca ao longo dos *frames*, tornando a tarefa de

rastrear-la bastante complexa para rastreadores mais simples que não são adaptados ou especializados no rastreamento de pequenos objetos.

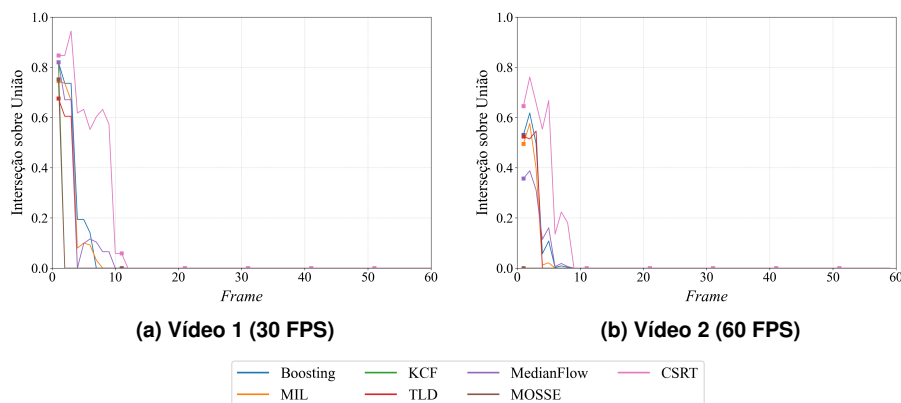


Figura 4. IoU dos rastreadores nos vídeos de partidas profissionais.

Como é possível observar na Figura 4, o algoritmo CSRT apresenta melhor desempenho, principalmente no vídeo de $1280 \times 720 px$, mas ainda insuficiente para garantir consistência. MOSSE e KCF apresentam os piores resultados, perdendo o objeto logo após o início do rastreamento. Por outro lado, 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.

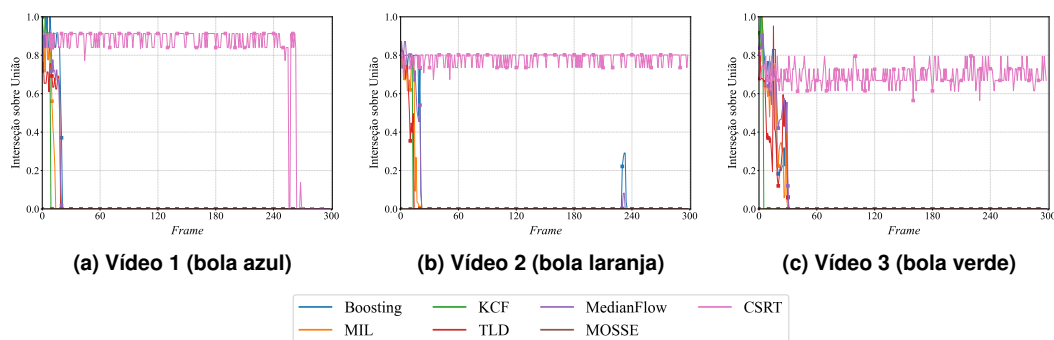


Figura 5. IoU dos rastreadores nos vídeos de ambiente controlado.

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. Mesmo em condições controladas, MOSSE e KCF mantêm desempenho insatisfatório, com o MOSSE sendo incapaz de manter o rastreamento por muitos quadros. O TLD também apresenta baixas taxas de IoU e inconsistência no rastreamento. Desempenho semelhante é observado na Subfigura 5c, Vídeo 3, onde, embora os rastreadores, em geral, tenham mantido o rastreamento por um maior número de *frames*, não se nota uma melhoria significativa na precisão.

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

Os resultados em termos de FPS indicam que os algoritmos de rastreamento mais precisos tendem a ser mais lentos na execução de suas tarefas. Na Tabela 1 são apresentadas as médias de FPS alcançadas pelos rastreadores em diferentes resoluções.

Tabela 1. Médias de FPS por rastreador e resolução.

Rastreador	30 FPS (1280 × 720)	60 FPS (1920 × 1080)
<i>Boosting</i>	35	25
CSRT	24	18
KCF	70	45
<i>MedianFlow</i>	50	35
MIL	40	30
MOSSE	90	55
TLD	25	20

Ao analisar a Tabela 1, observa-se uma relação inversa entre precisão e velocidade. O CSRT, com maior IoU, prioriza robustez sobre velocidade, enquanto o MOSSE, embora seja o mais rápido, apresenta precisão quase nula. Algoritmos como KCF e *MedianFlow* oferecem 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.

5.3. Resultados do Erro Médio de Rastreamento (*Mean Tracking Error - MTE*)

Na Figura 6 são exibidos os resultados em vídeos profissionais, representados em mapa de calor, no qual menores erros aparecem em verde e maiores, em vermelho.




Figura 6. Erro Médio de Rastreamento em vídeos de partidas profissionais.

Podemos observar na Figura 6 que o CSRT e o *Boosting* apresentam um desempenho intermediário, com valores próximos a 0.4 e 0.6, demonstrando dificuldades mesmo para os melhores rastreadores. Em contraste, MOSSE e KCF obtiveram os piores desempenhos, atingindo o erro máximo (1.0), o que indica falha completa no rastreamento. Na Figura 7, são apresentados os resultados referentes ao ambiente controlado, onde as diferenças entre os algoritmos se tornaram ainda mais evidentes.



Figura 7. Erro Médio de Rastreamento em vídeos de ambiente controlado.

Como ilustrado na Figura 7, 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 variabilidade (0.18 a 0.47), comprometendo sua confiabilidade, enquanto o KCF e MOSSE continuaram com desempenho insatisfatório.

6. Resultados da Análise Visual

A análise visual concentra-se no ambiente controlado, resultado ilustrado na Figura 8, representado, neste caso, pelo Vídeo 2, devido ao desempenho superior, em termos de MTE e IoU.

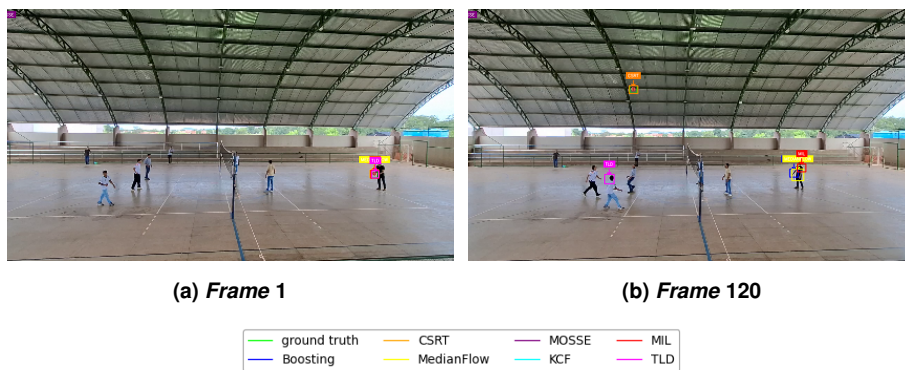


Figura 8. Análise visual do vídeo de cenário controlado.

No *Frame 1*, Subfigura 8a, 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 no *Frame 120*, Subfigura 8b.

7. Discussões

Dentre os algoritmos avaliados, o CSRT se destacou pelo melhor desempenho geral, com boa precisão e estabilidade, especialmente em ambientes controlados. No entanto, sua eficácia foi reduzida em jogos profissionais. Os algoritmos *Boosting* e *MedianFlow* apresentaram desempenho intermediário, com maior sensibilidade. Já o MOSSE e o KCF demonstraram grandes limitações, evidenciadas por menor precisão e instabilidade na identificação contínua dos objetos.

Esses achados corroboram os resultados de [Brdjanin et al. 2020], que destacaram o desempenho do MOSSE em termos de velocidade. No entanto, apesar de rápido, o MOSSE não atende às exigências de precisão. De forma semelhante, [Gudauskas and Matusėvičius 2021] observaram que, embora algoritmos clássicos como MOSSE e KCF ofereçam desempenho competitivo, abordagens baseadas em redes neurais demonstram maior robustez diante de oclusões.

Em contraste com os algoritmos clássicos avaliados, que apresentaram limitações em cenários reais de jogos, o método proposto por [Han et al. 2024] evidencia a eficácia de soluções especializadas, ajustadas às particularidades do domínio esportivo. Embora os algoritmos clássicos ainda apresentem vantagens em simplicidade e velocidade, sua eficácia em cenários esportivos é limitada. A adoção de modelos baseados em aprendizado profundo e o uso de estratégias híbridas representam caminhos promissores para o avanço do VOT no esporte.

8. Agradecimentos

Os autores agradecem ao Instituto Federal do Piauí (IFPI) pelo apoio institucional e financeiro concedido para a apresentação deste trabalho.

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.
- 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. 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.
- 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.
- 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.
- 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.
- Volleyball Playoffs (2024). Canal do YouTube: VolleyballPlayoffs. <https://www.youtube.com/@volleyballplayoffs>. 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.