



Monitoramento de Velocidade em Atletas de Natação via Visão Computacional: Uma Abordagem Desktop de Baixo Custo

Swimming Athlete Speed Monitoring via Computer Vision: A Low-Cost Desktop Approach

Paulo Junior Walbueno dos Santos

Graduando em Sistemas de Informação
Instituto Federal de São Paulo *Campus* Votuporanga
<https://orcid.org/0009-0005-6628-2594>
paulojunior6886@gmail.com

João Vitor Burnunssi

Bacharel em Sistemas de Informação
Instituto Federal de São Paulo *Campus* Votuporanga
<https://orcid.org/0009-0000-0546-7679>
burnunssi@gmail.com

Juliana de Fátima Franciscani

Mestrado em Engenharia Elétrica
Instituto Federal de São Paulo *Campus* Votuporanga
<https://orcid.org/0009-0004-1653-3458>
juliana.franciscani@ifsp.edu.br

Ivan de Oliveira Lopes

Doutorado em Engenharia Elétrica
Instituto Federal de São Paulo *Campus* Votuporanga
<https://orcid.org/0009-0005-3276-427X>
io.lopes@ifsp.edu.br

Histórico do artigo

Recebido em: 25.06.2026

Revisões solicitadas: 24.08.2026

Versão reformulada recebida: 08.09.2026

Aprovado em: 11.09.2026

Publicado em: 17.09.2026

RESUMO

O monitoramento do desempenho na natação é frequentemente realizado por meio de observação visual ou com o auxílio de sensores especializados. O alto custo do emprego de sensores para o monitoramento pode limitar o acesso e aquisição dessas tecnologias de análise de desempenho por diversas instituições. Este trabalho apresenta o desenvolvimento de um sistema de baixo custo para o monitoramento automatizado da velocidade de nadadores utilizando técnicas de visão computacional. A solução proposta emprega o modelo YOLOv8n para a detecção de nadador em vídeos, integrado a uma aplicação desktop desenvolvida em Python com a biblioteca PyQt5. O sistema permite o ajuste dinâmico das distâncias monitoradas, o cálculo automático da velocidade média e o armazenamento dos dados em formatos estruturados (CSV e TXT), possibilitando o acompanhamento histórico do desempenho dos atletas. Os resultados demonstraram a capacidade da ferramenta em identificar nadadores em ambiente real e fornecer métricas relevantes para a análise técnica dos treinamentos de forma automatizada e não invasiva. Além de apresentar baixo custo de implementação, a solução mostrou-se eficaz como ferramenta de apoio ao treinamento esportivo.

Palavras-chave: visão computacional; YOLOv8n; natação; análise de desempenho; monitoramento esportivo.

ABSTRACT

Swimming performance monitoring is frequently carried out through visual observation or with the aid of specialized sensors. The high cost of using sensors for monitoring can limit access to and acquisition of these performance analysis technologies by various institutions. This work presents the development of a low-cost system for automated monitoring of swimmer speed using computer vision techniques. The proposed solution employs the YOLOv8n model for swimmer detection in videos, integrated into a desktop application developed in Python with the PyQt5 library. The system allows for dynamic adjustment of monitored distances, automatic calculation of average speed, and data storage in structured formats (CSV and TXT), enabling historical tracking of athlete performance. The results demonstrated the tool's capability to identify swimmers in real-world environments and provide relevant metrics for technical training analysis in an automated and non-invasive manner. In addition to offering low implementation costs, the solution proved effective as a tool to support sports training.

Keywords: computer vision; YOLOv8n; swimming; performance analysis; sports monitoring.

Introdução

No esporte de alto rendimento, o avanço das tecnologias tem sido impulsionado, sobretudo, pela miniaturização de dispositivos eletrônicos e pela evolução dos sistemas de transmissão de dados, resultando em ganhos significativos de desempenho para os atletas. Entretanto, enquanto a maioria das soluções computacionais está voltada para modalidades praticadas em ambientes terrestres, no contexto da natação e de outras atividades aquáticas, os sistemas disponíveis ainda se baseiam predominantemente na observação visual humana ou em técnicas que exigem a conexão física do atleta a sensores e cabos invasivos (Giannetti et al., 2014).

Nos últimos anos, grandes empresas também têm investido na integração de técnicas de aprendizado de máquina para análise de desempenho em tempo real, evidenciando o potencial tecnológico dessa área. (Amazon Web Services, 2022)

Na natação, modalidade em que milésimos de segundo podem determinar resultados, o uso de instrumentos tecnológicos para análise de desempenho torna-se essencial. No entanto, os altos custos envolvidos frequentemente restringem o acesso a essas soluções a atletas olímpicos ou instituições de elite (Giannetti et al., 2014). Sistemas comerciais e sensores de telemetria aquática podem demandar infraestrutura dedicada, equipamentos especializados e soluções proprietárias. Em contrapartida, a abordagem proposta utiliza equipamentos de uso geral, como computadores convencionais e câmeras ou smartphones, além de frameworks gratuitos e de código aberto (Python, YOLOv8n e OpenCV), reduzindo custos associados à aquisição e ao licenciamento de tecnologias proprietárias.

Diante desse cenário, este trabalho apresenta uma proposta de baixo custo para o monitoramento automático da velocidade de nadadores, utilizando técnicas de Processamento Digital de Imagens (PDI) e Visão Computacional para extrair informações estruturadas a partir de sequências de vídeo. O sistema desenvolvido emprega o modelo de detecção YOLOv8n, integrado a uma interface desktop construída em Python com a biblioteca PyQt5.

A solução proposta permite a estimativa da velocidade média do atleta com base em sua passagem por marcações visuais configuráveis. Como diferencial técnico, o software incorpora a funcionalidade de entrada dinâmica de metadados, possibilitando que o usuário identifique o atleta e defina manualmente as distâncias reais de cada trecho analisado diretamente na interface. Além disso, o sistema exporta os resultados em formatos estruturados (TXT e CSV), viabilizando o acompanhamento longitudinal do desempenho esportivo de forma automatizada.

Referencial Teórico

O desenvolvimento deste trabalho fundamenta-se nos campos de Processamento Digital de Imagens (PDI), da Visão Computacional e da Aprendizagem de Máquina, áreas que de forma integrada, possibilitam a extração automática de informações a partir de imagens e vídeos e análise de parâmetros. Essas técnicas estão cada vez mais sendo empregadas em aplicações que exigem monitoramento, reconhecimento de padrões e análise em tempo real, o que possibilita a aplicação dessas ferramentas em diferentes contextos, como no esporte de alto rendimento.

O Processamento Digital de Imagens constitui a etapa inicial desse processo, responsável pela aquisição, melhoria e transformação de imagens digitais, possibilitando que informações contidas nas imagens sejam convertidas em dados passíveis de interpretação por sistemas computacionais. De acordo com Gonzalez e Woods (2018), o processamento de imagens compreende operações como filtragem, segmentação e extração das características,

reduzindo ruídos, destacando regiões de interesse e preparando os dados para etapas posteriores de análise.

A partir das informações processadas, a Visão Computacional busca reproduzir a capacidade humana de interpretar cenas e compreender objetos presentes em ambientes reais. Segundo Russell e Norvig (2021), essa área utiliza algoritmos capazes de transformar informações visuais em conhecimento estruturado, o que permite a automatização de tarefas como monitoramento, inspeção, rastreamento e reconhecimento de objetos. No contexto esportivo, essas técnicas possibilitam o acompanhamento automático de atletas durante treinamentos e competições, reduzindo a dependência da análise exclusivamente visual realizada por treinadores.

O avanço da Visão Computacional foi potencializado pela evolução das técnicas de Aprendizagem de Máquina, especialmente com a utilização das Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNNs). Diferentemente dos métodos tradicionais de processamento de imagens, que dependiam da definição manual de características relevantes, as CNNs são capazes de aprender automaticamente padrões presentes nas imagens por meio de múltiplas camadas convolucionais.

Conforme destacam Goodfellow, Bengio e Courville (2016), essa arquitetura permite a extração hierárquica de atributos, identificando desde características simples, como bordas e texturas, até padrões complexos, como formas e objetos completos. O funcionamento dessas redes baseia-se em processos de treinamento supervisionado, nos quais os parâmetros internos são ajustados iterativamente para minimizar erros de classificação e detecção, conforme descrito por Haykin (2001).

Entre os modelos de detecção de objetos baseados em CNNs, destaca-se o algoritmo YOLO (You Only Look Once), proposto por Redmon et al. (2016). Sua principal característica consiste em reformular o problema da detecção de objetos como uma única etapa de regressão, permitindo que a localização e a classificação dos objetos sejam realizadas simultaneamente. Essa abordagem proporciona elevado desempenho computacional, tornando o modelo adequado para aplicações que exigem processamento em tempo real.

Neste trabalho foi utilizada a versão YOLOv8n (nano), desenvolvida pela Ultralytics, pertencente à família YOLOv8. O modelo apresenta arquitetura implementada na plataforma PyTorch e foi selecionado por sua combinação entre eficiência computacional e capacidade de detecção. Essas características tornam o YOLOv8n adequado para aplicações que envolvem detecção de objetos em movimento, como o monitoramento de atletas em ambiente aquático.

Para viabilizar a implementação do sistema proposto, foram utilizadas bibliotecas amplamente consolidadas na comunidade científica. A linguagem Python foi escolhida como plataforma de desenvolvimento devido à sua ampla utilização em aplicações de Ciência de Dados, Inteligência Artificial e Visão Computacional, além da extensa disponibilidade de bibliotecas especializadas. A interface gráfica foi desenvolvida utilizando a biblioteca PyQt5, permitindo a construção de uma aplicação *desktop* interativa e multiplataforma, voltada à utilização por treinadores e equipes técnicas. Já as operações de leitura dos vídeos, manipulação dos quadros (*frames*), calibração geométrica das raia e processamento das imagens foram implementadas por meio da biblioteca OpenCV, amplamente empregada em aplicações de Visão Computacional devido à sua eficiência e variedade de algoritmos para processamento de imagens e vídeos.

Metodologia

A pesquisa caracteriza-se como de natureza aplicada, com uma abordagem quantitativa, que tem como objetivo desenvolver e avaliar um sistema computacional para o monitoramento

automático da velocidade de nadadores a partir da análise de vídeos. A metodologia compreendeu as etapas de obtenção e preparação do conjunto de dados, treinamento do modelo de detecção, desenvolvimento da aplicação computacional e validação funcional do sistema.

Inicialmente, foi construído um conjunto de dados (*dataset*) próprio, composto por 77 imagens selecionadas, para o treinamento do modelo de detecção de objetos. As imagens foram capturadas em ambiente real no Parque Aquático Savério Maranhão, localizado no município de Votuporanga-SP, contemplando diferentes condições de iluminação e variações inerentes ao ambiente aquático. Posteriormente, as imagens foram anotadas manualmente por meio da plataforma Roboflow, responsável pela criação das caixas delimitadoras (*bounding boxes*).

Após a etapa de anotação, o conjunto de dados foi dividido em subconjuntos destinados ao treinamento e validação. O treinamento foi realizado utilizando a arquitetura YOLOv8n ao longo de 50 épocas em ambiente computacional com suporte a processamento gráfico (GPU). Isso possibilitou a convergência da rede neural e a adequação na detecção do nadador em cenários com distorções ópticas.

Concluída a etapa de treinamento, foi desenvolvido um sistema computacional em linguagem Python, integrando diferentes bibliotecas especializadas para processamento de imagens e desenvolvimento da interface gráfica. A biblioteca OpenCV foi empregada para leitura e processamento dos vídeos, extração dos *frames* e execução das operações necessárias ao monitoramento do atleta. As operações matemáticas foram implementadas com auxílio da biblioteca NumPy, enquanto a interface gráfica foi desenvolvida utilizando a biblioteca PyQt5, permitindo uma interação intuitiva entre o usuário e o sistema.

Durante a execução da aplicação, o usuário seleciona o vídeo a ser analisado e define visualmente duas linhas de referência correspondentes ao início e ao término do trecho de interesse. Além disso, informa a distância real entre essas marcações e identifica o atleta analisado por meio da interface. O sistema processa automaticamente cada quadro do vídeo utilizando o modelo YOLOv8n, identificando a posição do nadador ao longo da sequência de imagens. A velocidade média é então calculada pela razão entre a distância previamente informada e o intervalo de tempo correspondente à passagem do atleta entre as duas linhas de referência, sendo esse tempo obtido a partir da taxa de quadros por segundo (*Frames Per Second – FPS*) do vídeo.

Como evolução da ferramenta desenvolvida, foram incorporadas funcionalidades destinadas ao gerenciamento dos dados produzidos durante as análises. A interface passou a permitir a inserção dinâmica de metadados, incluindo a identificação do atleta e a definição individual das distâncias analisadas, possibilitando maior flexibilidade na utilização do sistema em diferentes sessões de treinamento.

Também foi implementado um mecanismo inteligente de persistência de dados, denominado Smart Select, responsável pelo gerenciamento automático dos arquivos de resultados. Ao selecionar um arquivo de histórico nos formatos TXT ou CSV, o sistema identifica automaticamente seu arquivo correspondente e realiza a gravação em modo de anexação, preservando todas as análises anteriormente registradas. Dessa forma, novas avaliações são incorporadas ao histórico existente sem sobrescrever informações anteriores, permitindo o acompanhamento longitudinal do desempenho do atleta e facilitando a comparação entre diferentes sessões de treinamento.

Resultados e Discussão

A avaliação experimental do sistema teve como objetivo verificar a eficiência do modelo de detecção desenvolvido para o ambiente aquático, bem como analisar o desempenho da

aplicação na estimativa automática da velocidade de nadadores. Os testes foram realizados utilizando vídeos capturados em condições reais de treinamento.

Os resultados demonstraram que o modelo YOLOv8n, treinado especificamente com imagens do domínio aquático, apresentou desempenho robusto e adequado no conjunto de validação, inclusive diante de condições características do ambiente analisado, como reflexos na superfície da água e oclusões parciais. Para a avaliação técnica da rede no escopo de detecção de objetos, o modelo customizado alcançou uma Precisão (Precision) de **87%** e um Recall de **83%**, resultando em um F1-Score de aproximadamente **85%**. Complementarmente, a métrica mAP@0.5 (mean Average Precision) atingiu **88%**, indicando bom desempenho global de detecção considerando o limiar IoU de 0,5. Esse equilíbrio métrico indica baixa incidência de falsos positivos e falsos negativos, possibilitando o rastreamento contínuo do atleta durante o percurso. A Figura 1 ilustra o rastreamento do nadador em ambiente real.


Figura 1 - Detecção do nadador em ambiente real com presença de reflexos e luminosidade variável



Fonte: Os autores, 2026.

A precisão da detecção refletiu diretamente na qualidade das métricas geradas. Após a identificação do nadador, a aplicação registrou os instantes correspondentes à passagem pelas linhas de referência e calculou automaticamente a velocidade média do percurso (em m/s e km/h) a partir do diferencial de quadros (FPS). A validação sistêmica evidenciou que a ferramenta executa essa consolidação de forma imediata. A entrada de metadados (como a identificação do atleta e a distância) demonstrou-se funcional para estruturar os dados extraídos, sendo todos exportados corretamente e de forma automática para arquivos TXT e CSV. Os resultados consolidados podem ser observados na Figura 2, evidenciando o sistema como uma alternativa técnica eficaz e objetiva.

Figura 2 - Interface do aplicativo exibindo resultados consolidados e histórico fixado



Fonte: Os autores, 2026.

De maneira geral, os resultados obtidos demonstram que a integração entre técnicas de Processamento Digital de Imagens, Visão Computacional e Aprendizagem de Máquina constitui uma alternativa viável para o monitoramento automático de nadadores em ambientes reais. A utilização de um modelo treinado especificamente para esse domínio mostrou-se fundamental para aumentar a robustez da detecção, enquanto a interface desenvolvida tornou a ferramenta acessível e de fácil utilização. Dessa forma, o sistema apresenta potencial para ser empregado como uma solução para o acompanhamento do desempenho esportivo, especialmente em clubes e centros de treinamento que não dispõem de equipamentos comerciais de elevado custo.

Considerações Finais

Este trabalho apresentou o desenvolvimento de um sistema baseado em técnicas de Processamento Digital de Imagens, Visão Computacional e Aprendizagem de Máquina para o monitoramento automático da velocidade de nadadores em ambiente aquático. Os resultados obtidos demonstraram que a solução proposta atingiu o objetivo de disponibilizar uma ferramenta acessível, e não invasiva para a análise do desempenho esportivo, reduzindo a dependência de equipamentos especializados e de custo elevado.

A utilização do modelo YOLOv8n, treinado com um conjunto de dados construído especificamente para o domínio aquático, mostrou-se fundamental para garantir maior robustez na detecção do nadador, mesmo em condições desafiadoras, como reflexos na superfície da água, variações de luminosidade e mudanças na posição corporal do atleta. O desempenho obtido evidencia a importância da especialização do modelo para aplicações em ambientes específicos, contribuindo para a confiabilidade das informações produzidas pelo sistema.

Além da detecção automática do atleta, a aplicação desenvolvida incorporou funcionalidades que ampliam sua aplicabilidade prática em treinamentos esportivos. A interface gráfica permite a configuração dinâmica dos parâmetros de análise, incluindo a identificação do atleta e a definição das distâncias percorridas, entregando relatórios prontos que facilitam o acompanhamento da evolução do desempenho dos nadadores ao longo do tempo, sem a necessidade de infraestrutura dedicada.

Embora os resultados obtidos tenham sido satisfatórios, algumas limitações ainda podem ser observadas. O sistema depende de vídeos capturados com posicionamento adequado da câmera, de forma a minimizar oclusões parciais e garantir a correta visualização do atleta durante todo o percurso. Além disso, fatores ambientais, como reflexos intensos e variações extremas de iluminação, podem influenciar o desempenho do modelo em determinadas situações.

Como perspectivas para trabalhos futuros, pretende-se ampliar as funcionalidades do sistema por meio da migração para uma arquitetura web baseada em FastAPI, permitindo o processamento remoto dos vídeos e o armazenamento centralizado das informações. Também se prevê a incorporação de novas métricas de desempenho, como frequência de braçadas, tempo de reação, identificação automática dos diferentes estilos de nado e geração de relatórios estatísticos, ampliando o potencial da ferramenta como apoio ao treinamento esportivo e ao acompanhamento técnico de atletas em diferentes níveis de desempenho.

Referências

Amazon Web Services. (2022). *How Swimming Australia uses machine learning for real-time training pool analytics with AWS Panorama*. <https://aws.amazon.com/pt/blogs/media/how-swimming-australia-uses-machine-learning-for-real-time-training-pool-analytics-with-aws-panorama/>

Bradski, G. (2000). The OpenCV Library. Dr. Dobb's Journal of Software Tools. <https://opencv.org/about/>

Giannetti, M. R. S., Tierra Criollo, C. J., & Boaventura, W. C. (2014). Monitoramento da natação usando imagens. *Anais do 24º Congresso Brasileiro de Engenharia Biomédica*. https://www.canal6.com.br/cbeb/2014/artigos/cbeb2014_submission_061.pdf

Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Haykin, S. (2001). *Redes neurais: princípios e prática*. Bookman Editora.

Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Kopf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J., & Chintala, S. (2019). PyTorch: An Imperative Style, High-Performance Deep Learning Library. *Advances in Neural Information Processing Systems* 32. https://papers.nips.cc/paper_files/paper/2019/file/bdbca288fee7f92f2bfa9f7012727740-Paper.pdf

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*. <https://arxiv.org/abs/1506.02640>

Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.

Victor, B., He, Z., Morgan, S., & Miniutti, D. (2017). *Continuous video to simple signals for swimming stroke detection with convolutional neural networks*. <https://arxiv.org/abs/1705.09894>