

# Uma proposta para classificação de equipes em esportes coletivos

Lucas Reis Abreu<sup>1</sup>, Victor Henrique Bezerra de Lemos<sup>2</sup>  
Geraldo Braz Junior<sup>2</sup>

<sup>1</sup> Universidade Federal do Maranhão - UFMA

<sup>2</sup>Núcleo de Computação Aplicada - UFMA

lucasreisabreu@hotmail.com, {victorhbl12, ge.braz}@gmail.com

**Abstract.** *The sports industry is a billion-dollar business and grows more and more each year. Sport videos published in magazines and commercials were analyzed. The work had a proposal to carry out the tracking of the players in video games recorded by the cameras of different sports games. With the use of the algorithm HOG Pedestrians Detection, so much for the location of the players that for the design of the bounding boxes of each one, we were able to apply several sessions of trainings and tests that culminated in the classification and differentiation of the players in his respective teams.*

**Resumo.** *A indústria esportiva é um negócio bilhonário e cresce cada vez mais todo ano e a análise inteligente de vídeos esportivos tem sido utilizada amplamente em pesquisas e aplicações comerciais. Este trabalho apresenta uma proposta para realizar tracking (ou rastreamento) dos jogadores a partir de vídeos gravados por câmeras de TV de diferentes jogos esportivos. Com a utilização do algoritmo HOG Pedestrian Detection, tanto para localização dos jogadores quanto para o desenho dos bounding boxes respectivos de cada um, fomos capazes de aplicar diversas sessões de treinos e testes que culminaram na classificação e diferenciação dos jogadores em seus respectivos times.*

## 1. Introdução

Em 2017, a indústria esportiva movimentou cerca de R\$ 67 bilhões de acordo com o Assessor da Presidência da Fundação Getúlio Vargas, Istvan Kasznar [Cabral 2013]. A análise inteligente de vídeos esportivos, tem sido utilizada amplamente em pesquisas e aplicações comerciais. Dentre as várias aplicações no mundo dos esportes, a identificação automática dos jogadores tem um grande valor, principalmente para transmissões de televisão. Visto isso, é importante distinguir os jogadores de cada equipe, através de vídeos de jogos esportivos, capturados por câmeras de TV em tempo real.

De acordo com os estudos de [Cheshire et al. ], em que o autor apresenta uma ideia similar, foi realizada a detecção dos jogadores de cada time em partidas de basquete, demonstrando também a avaliação do resultado de seu desempenho nesse cenário de distinção jogador-equipe. Para isso, ele fez uso do HOG Pedestrian Detection e uma classificação baseada em cor. Em [Lu et al. 2013], também se faz presente a detecção dos esportistas em partidas de basquete, porém seu diferencial é que cada objeto detectado foi classificado em três classes: "Time A", "Time B" e "Outros", a fim de posteriormente,

identificar quem exatamente é cada jogador usando a técnica de Regressão Logística. O trabalho aqui discutido, focou-se no treinamento da ferramenta HOG Pedestrian, disponibilizada na plataforma OpenCV, responsável pela detecção de pedestres como o próprio nome sugere. O referido estudo se diferencia dos demais por não se limitar à apenas um esporte, podendo ser utilizado em diversos desportos coletivos com dois times bem definidos.

## 2. Ferramentas Utilizadas

Desenvolver um algoritmo para realizar o processamento de imagens em tempo real demandaria tempo, assim sendo, utilizou-se a biblioteca de visão computacional do OpenCV [Bradski and Kaehler 2008]. Sendo a principal biblioteca de código aberto para a visão computacional, o OpenCV oferece processamento de imagem e aprendizagem de máquina principalmente para operações em tempo real. A biblioteca dá suporte a algumas linguagens de programação, tais como C/C++, Python e Java. Com diversas opções ofertadas por ela, a mesma nos auxiliou na questão da detecção de indivíduos em uma dada imagem, onde este trabalho foi realizado principalmente pelo HOG Pedestrian Detection [Dalal and Triggs 2005].

Uma vez que a linguagem escolhida foi o Python, utilizou-se também a biblioteca Scikit-learn [Pedregosa et al. 2011]. Esta por sua vez, engloba diversos algoritmos de classificação, regressão e agrupamento. Tal ferramenta foi responsável pela classificação dos jogadores, detectados anteriormente, em seus respectivos times que foram representados por duas classes definidas na fase de treino, que são elas: "Time A" e "Time B". Como dentro do vídeo existem muitos elementos extras, tais como juizes, redes, propagandas, torcidas e entre outros, foi necessário a criação de outra classe denominada "Outros" para englobar tais objetos.

## 3. Metodologia

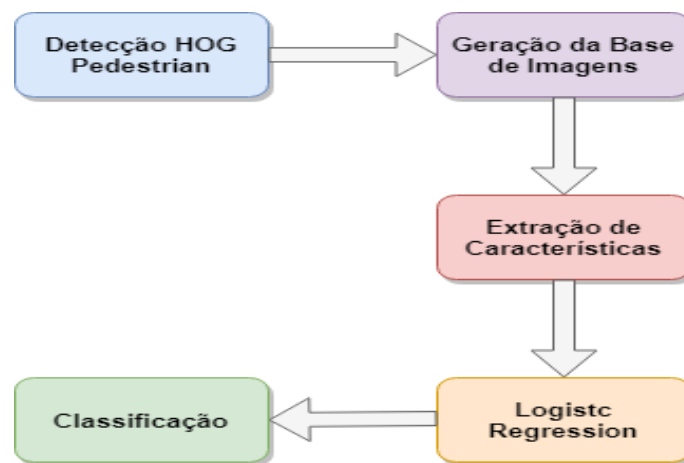
A princípio, foram utilizados vídeos de jogos de futebol de campo, porém ao final optou-se por manipular vídeos de esportes de quadra como o futsal, no qual, realizaram-se algumas edições, tais como a retirada de replays, publicidade e outros, afim de maximar o tempo útil das partidas. Para a implementação do objetivo, foram testados dois processos metodológicos sobre uma base de dados construída com 1.722 (mil setecentas e vinte e duas) imagens ao total, sendo distribuídas em: **Basquete (595), Futsal (554) e Vôlei (573)**.

O primeiro método consistiu em realizar o tracking dos jogadores através de duas etapas:

1. **Primeira etapa:** Extração do campo e de possíveis propagandas presentes no vídeo;
2. **Segunda etapa:** Executar o closing do resultado da extração. Tal processo foi implementado com o algoritmo **Background Subtractor MOG**, que por sua vez é uma técnica amplamente e comumente utilizada para gerar uma máscara de primeiro plano (ou seja, uma imagem binária que contém os pixels pertencentes a objetos em movimento na cena) usando câmeras estáticas. O algoritmo em questão calcula a máscara de primeiro plano executando uma subtração entre o quadro atual e um modelo de fundo, contendo a parte estática da cena ou, mais

em geral, tudo o que pode ser considerado como fundo, dado as características da cena observada.

Após esse encadeamento, com a imagem obtida pelo MOG, aplicava-se o **Closing**, sendo uma ferramenta muito útil em fechar pequenos orifícios dentro dos objetos de primeiro plano, ou pequenos pontos negros no objeto, fornecendo assim, um melhor contorno dos jogadores. Com esse processo foram obtidos resultados satisfatórios no rastreamento dos esportistas, porém ao seguir para a classificação, onde almejava-se seguir a ideia proposta em [Lu et al. 2013], de fixar três tipos de classes ("Time A", "Time B" e "Outros"), foram detectados problemas em abstrair características para prosseguir utilizando a metodologia, visto que não se obtinha bons resultados em esportes de quadra.



**Figura 1. Metodologia Utilizada.**

Assim, uma segunda metodologia foi pensada, apresentada na Figura 1, baseada principalmente na utilização do algoritmo de Detecção HOG Pedestrian Detection, este por sua vez, é fornecido no OpenCV com um modelo pré-treinado HOG + Linear SVM, que pode ser usado para detecção de pedestres em imagens. A sequência de passos da nova abordagem efetua-se da seguinte maneira:

1. Aplicação do algoritmo HOG na sequência do vídeo desejado, onde serão rastreados os jogadores presentes no decorrer dos frames sem realizar distinção entre os times;
2. Após o emprego do HOG, tem-se a geração da base de Imagens com cada jogador detectado pelo algoritmo, onde possivelmente existem alguns reconhecimentos errôneos, como por exemplo, dois jogadores ocupando o mesmo bounding box desenhado pelo programa. Para efetivar o futuro treino da classificação foram removidas imagens como essas da base de dados;
3. Em seguida, sucedem-se as etapas de extração de características e uso da técnica de Regressão Logística, para classificar os jogadores em seus times correspondentes. Tal extração é baseada no histograma de cor de cada jogador detectado;
4. Finalizando o fluxograma tem-se a etapa de classificação, que corresponde às duas últimas etapas do esquema. Nessa etapa é aplicada a técnica de Regressão Logística, sendo compreendida como uma técnica de classificação probabilística, a qual oferece suporte a classificações binárias e multi-classes uma vez que seguiu-se a mesma ideia do [Cheshire et al. ] de construir 3 (três) classes para classificar

os jogadores identificados. Nessa fase, a base foi dividida em 70% voltada ao treino e os 30% restantes para teste, onde o algoritmo irá abstrair o resultados obtidos durante a fase de treino.

#### 4. Resultados

Com a utilização do HOG obteve-se, na maioria dos casos, resultados satisfatórios na detecção dos jogadores. Quando houveram erros, estes estavam relacionados a inclusão de objetos externos como a torcida, juiz(es) e gandulas, ou a oclusão parcial ou integral de jogadores.

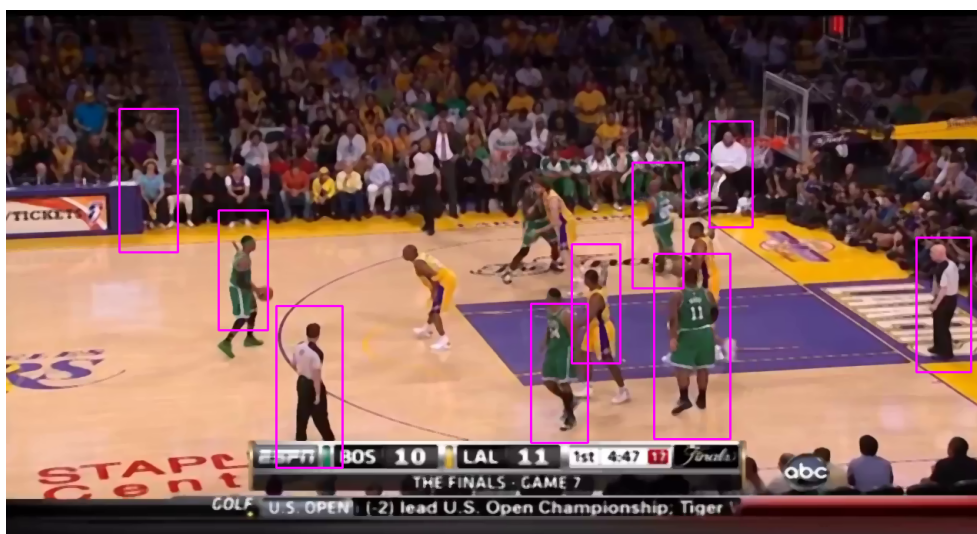


Figura 2. Detccão do HOG - Partida de Basquete.

Tabela 1. Precisão alcançada em cada esporte para cada classe.

Esporte	Time A	Time B	Outros
Basquete	94%	86%	90%
Futsal	93%	93%	90%
Volei de Praia	99%	98%	94%

Tabela 2. Número de imagens utilizadas para classificação de cada classe.

Esporte	Time A	Time B	Outros	Total de Imagens
Basquete	328	132	135	595
Futsal	302	95	157	554
Volei de Praia	365	106	102	573

A Figura 2 apresenta a detecção de jogadores dos times de basquete. Neste caso, percebeu-se que alguns dos indivíduos não foram identificados, como é possível observar

na Tabela 1. Isso se deve, basicamente pela proximidade da torcida à quadra e da constante oclusão dos jogadores durante uma marcação entre os competidores ou disputa de bola. Na Tabela 2 pode-se visualizar de maneira análoga a Tabela 1, quantas imagens do banco de dados foram utilizadas para obtenção do resultado demonstrado.



**Figura 3. Detecção do HOG - Partida de Futsal.**

Nos testes com futsal, Figura 3, a detecção já sofre uma significativa melhora, uma vez que a torcida já se encontra mais afastada da quadra, porém os técnicos e juízes continuam sendo detectados juntamente com os jogadores, mas estes são distinguidos na etapa de classificação.



**Figura 4. Detecção do HOG - Partida de Volei de Praia.**

As melhores detecções foram feitas com as imagens obtidas dos vídeos de vôlei de praia, Figura 4, já que as equipes são mais bem distribuídas e com apenas dois jogadores em cada equipe, diminuindo a chance de oclusões. Os resultados alcançados na classificação, assemelham-se aos apresentados no trabalho de [Lu et al. 2013].

## 5. Conclusão

Com as imagens aqui demonstradas, expõe-se que o trabalho alcançou seu objetivo central, uma vez que a aplicação foi visivelmente capaz de distinguir os jogadores por si só como elementos individuais, onde cada esportista teve seu bounding box perfeitamente definido. Além disso, observa-se que os indivíduos foram muito bem classificados em suas respectivas classes (times) na maioria dos casos, além de alocar os resultados de falsos-positivos em uma outra classe denominada de "Outros".

Como trabalhos futuros, o ideal é diminuir alguns problemas encontrados, tais como: oclusão de jogadores e múltiplos jogadores em uma mesma detecção, fato que acaba acarretando em um mal desenho do bounding box. Além disso, se vê como interessante a possibilidade de testar outras técnicas para a detecção dos jogadores, assim como outros métodos para remoção do fundo.

## Referências

- Bradski, G. and Kaehler, A. (2008). *Learning OpenCV: Computer vision with the OpenCV library*. "O'Reilly Media, Inc."
- Cabral, M. (2013). Vende-se. *Página 22*, (75):20–24.
- Cheshire, E., Halasz, C., and Perin, J. Player tracking and analysis of basketball plays.
- Dalal, N. and Triggs, B. (2005). Histograms of oriented gradients for human detection. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 1, pages 886–893. IEEE.
- Lu, W.-L., Ting, J.-A., Little, J. J., and Murphy, K. P. (2013). Learning to track and identify players from broadcast sports videos. *IEEE transactions on pattern analysis and machine intelligence*, 35(7):1704–1716.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., et al. (2011). Scikit-learn: Machine learning in python. *Journal of machine learning research*, 12(Oct):2825–2830.