

Uma proposta para classificação de equipes em esportes coletivos

Victor Henrique Bezerra de Lemos¹, Lucas Reis Abreu²

¹Departamento de Informática – Universidade Federal do Maranhão (UFMA)
Caixa Postal 15.064 – 65080-805 – São Luís – MA – Brazil

***Resumo.** Através deste trabalho foi desenvolvido uma aplicação capaz de realizar o 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, para a localização dos jogadores e desenho dos bounding boxes respectivos de cada um, fomos capazes de aplicar treinos e testes para a classificação e diferenciação dos jogadores em seus respectivos times, para isso nos utilizamos de 3 (três) classes para realizar tal tarefa, sendo duas delas direcionadas para os times: TeamA e TeamB; e a última classe: Others para alocar outros elementos que não eram jogadores, como por exemplo juízes, propagandas, torcida, entre outros.*

1. Introdução

Análise inteligente de vídeos esportivos tem sido utilizada amplamente em pesquisas e aplicações comerciais. Como esta técnica apresenta diversos obstáculos, neste trabalho o foco foi resolver a questão de identificação dos jogadores e distinguir a que equipe cada um deles pertence, através de vídeos de jogos esportivos, capturados por câmeras de TV. Nosso trabalho focou-se basicamente no treinamento da ferramenta HOG Pedestrian, disponibilizada na plataforma OpenCV que realiza a detecção de pedestres, para realizar a detecção dos jogadores e avaliar os resultados de seu desempenho nesse cenário de distinção de jogador-equipe, além de se basear no trabalho visto em [Cheshire et al.] onde apresenta uma ideia similar. Nosso trabalho apresenta certa relevância uma vez que ele não se limita à um esporte apenas, podendo ser utilizado em diversos jogos de esportes coletivos.

2. Metodologia

O presente trabalho foi desenvolvido inteiramente na plataforma do OpenCV e como base de dados utilizamos vídeos de jogos de futebol de campo, mas no final optamos por usar vídeos de esportes de quadra disponibilizados no youtube, no qual realizamos algumas edições como a retirada de replays, publicidade e entre outros, afim de maximizar o tempo útil das partidas. Para implementação de nosso objetivo tentamos dois processos metodológicos. O primeiro consistia em realizar o tracking dos jogadores através de duas etapas:

1. A primeira delas era a extração do campo e de possíveis propagandas presentes no vídeo;
2. Já a segunda consistia em realizar o closing do resultado da extração. Tal extração era realizada 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. Como o nome sugere, o algoritmo 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.

Com a imagem obtida pelo MOG aplicavá-se o **Closing** que é uma ferramenta muito útil em fechar pequenos orifícios dentro dos objetos de primeiro plano, ou pequenos pontos negros no objeto, nos fornecendo assim um melhor contorno dos jogadores, onde pode ser visualizado abaixo:

Com esse processo obtiamos resultados satisfatórios no rastreamento dos jogadores, mas ao seguir para a classificação, onde desejávamos seguir a ideia proposta em [Lu et al. 2013] de fixar três tipos de classes (TeamA, TeamB e Others) encontramos problemas em abstrair características para prosseguir utilizando a metodologia, visto que não funcionava tão bem em esportes de quadra, o que acabou sendo nosso maior foco.

Como solução resolvemos utilizar outra abordagem, com um algoritmo diferente, como pode ser visualizado na figura 1 logo abaixo.

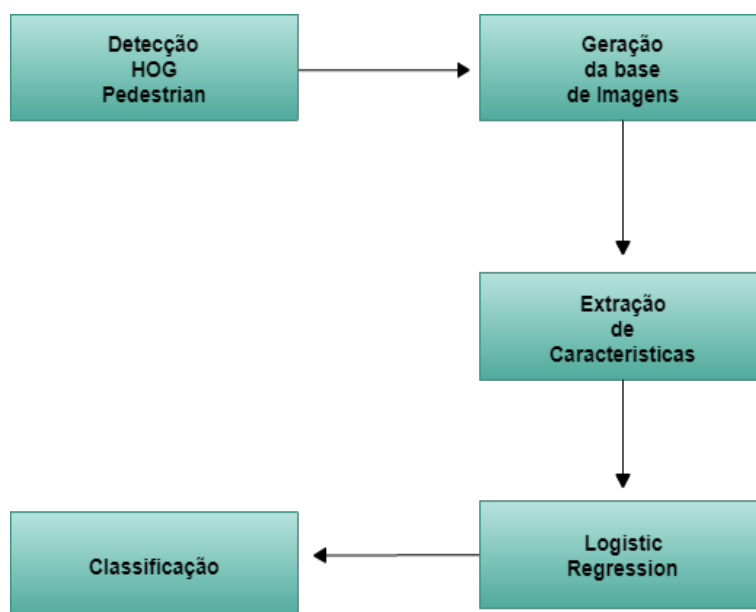


Figure 1. Metodologia Utilizada.

A nova metodologia como ilustrada acima foi baseada principalmente na utilização do algoritmo de Detecção HOG Pedestrian, este por sua vez é fornecido no OpenCV com um modelo pré-treinado HAG + Linear SVM que pode ser usado para realizar a detecção de pedestres em imagens e fluxos de vídeo. (talvez referenciar um artigo ou site sobre o HOG). A sequência de passos da nova abordagem seria da seguinte maneira:

1. Aplicar o algoritmo HOG a sequência do vídeo desejado, onde serão rastreados os jogadores presentes no decorrer dos frames sem realizar distinção entre os times.

2. Após a aplicação do HOG teremos a geração da base de Imagens com cada jogador detectado pelo algoritmo, podendo existir ainda alguns reconhecimentos errôneos, como por exemplo dois jogadores ocupando o mesmo boundingbox desenhado pelo programa. Para efetivar o futuro treino da nossa classificação removemos imagens como essa da nossa base de dados.
3. Em seguida realizamos as etapas de extração de características e uso do Logistic Regression para tentar separar os jogadores em seus times correspondentes. Tal extração é feita utilizando-se do algoritmo em questão, que é uma técnica de classificação probabilística. Além disso ele se baseia em uma classificação binária que está intimamente relacionado com o Support Vector Machines (SVM). Como nos baseamos na mesma ideia do [Cheshire et al.] de construir 3 (três) classes para separar os jogadores identificados, o algoritmo foi bastante útil, uma vez que ele oferece suporte a classificações binárias e multi-classes. Para treinar o classificador de regressão logística, são utilizados os algoritmos Descent gradiente de gradiente e Mini-Batch Gradient Descent.
4. Finalizando nosso fluxograma temos a etapa final que diz respeito a parte de classificação, onde o Logistic Regression irá dividir a base de imagens, obtida no item 2, pela metade, no qual 50% dessa divisão será destinada a fase de treinos da máquina e o restante ficará para a parte dos testes, onde ele irá abstrair o resultados obtidos durante a fase de treino.

3. Resultados

Com a utilização do HOG tivemos um número de resultados satisfatórios na detecção dos jogadores e outros com alguns erros de identificação, como na inclusão de objetos da torcida ou do ambiente como poderá ser visto nas figuras a seguir.

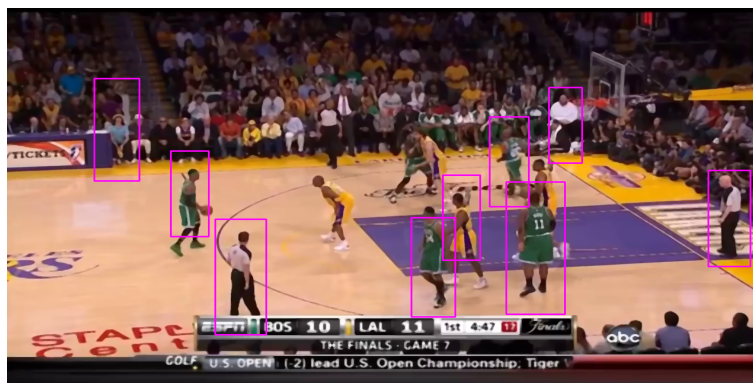


Figure 2. Detecção do HOG - Partida de Basquete.

Como visto na Figura 2 acima a detecção dos jogadores dos times de basquete não foi totalmente precisa, 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.

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



Figure 3. Detecção do HOG - Partida de Futsal.




Figure 4. Detecção do HOG - Partida de Volei de Praia.

As melhores detecções foram feitas com as imagens obtidas dos vídeos de volei de praia, como pode ser visto abaixo, já que as equipes são mais bem distribuídas e não há oclusões uma vez que a quantidade de integrantes é menor.

Sobre os resultados da parte de classificação nos aproximamos do trabalho apresentado em [Lu et al. 2013]. Seguindo a ordem das imagens dispostas acima, temos os seguintes resultados para a classificação:

Basquete

1. TimeA com 94% de precisão utilizando 328 imagens
2. TimeB com 86% de precisão utilizando 132 imagens
3. Others com 90% de precisão utilizando 135 imagens

Futsal

1. TimeA com 93% de precisão utilizando 302 imagens
2. TimeB com 93% de precisão utilizando 95 imagens
3. Others com 90% de precisão utilizando 157 imagens

Volei de Praia

1. TimeA com 99% de precisão utilizando 365 imagens
2. TimeB com 98% de precisão utilizando 106 imagens
3. Others com 94% de precisão utilizando 102 imagens

4. Conclusão

Com base nos argumentos e resultados apresentados neste artigo, pode-se concluir que o trabalho alcançou seu objetivo central, uma vez que a ferramenta apresentou uma elevada acuracia, na maioria dos casos mostrando um resultado maior que 90%, em distinguir os jogadores em seus devidos times, além de ainda alocar os falsos-positivos em outra classe, denominada de Others. Sobre os problemas de oclusão de jogadores, e multiplas pessoas em um mesmo bounding boxe, fica como trabalho futuro a ideia de utilizar os graficos de histogramas para a detecção dos jogadores.

References

- Cheshire, E., Halasz, C., and Perin, J. Player tracking and analysis of basketball plays.
- 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.