

MÉTODO PARA IDENTIFICAÇÃO DE ATIVIDADES COM ACELERÓMETRO E MAGNETÓMETRO DE DISPOSITIVOS MÓVEIS: UMA PROPOSTA DE ANÁLISE DOS DADOS RECOLHIDOS

Method for identifying activities with accelerometer and magnetometer of mobile devices: A proposal for analyzing the collected data

Ivan Miguel Pires

Instituto Politécnico de Santarém - Escola Superior de Gestão e Tecnologia, Portugal

impires@it.ubi.pt | ORCID: 0000-0002-3394-6762

Paulo Jorge Coelho

Instituto Politécnico de Leiria, Portugal

paulo.coelho@ipleiria.pt | ORCID: 0000-0002-4383-0472

Norberto Jorge Gonçalves

Universidade de Trás-os-Montes e Alto Douro, Portugal

njg@utad.pt | ORCID: 0000-0002-9218-2934

RESUMO

INTRODUÇÃO:

A deteção de atividades físicas por meio da fusão de dados de acelerómetro e magnetómetro de dispositivos móveis é de grande importância em várias aplicações, como monitorização de saúde, rastreamento de condição física e análise de movimentos. O objetivo deste estudo consiste na fusão de dados relacionados com cinco atividades físicas, tais como subir escadas, descer escadas, andar, estar parado e correr, com recurso aos dados adquiridos com o acelerómetro e magnetómetro em trechos de 5 segundos, para a extração de características dos sinais capturados e identificação das diferentes atividades recorrendo a métodos de inteligência artificial.

MÉTODOS:

O processo para a análise consiste em várias fases, tais como aquisição de dados, processamento de dados, limpeza dos dados, extração de características, fusão dos dados processados e aplicação de métodos de inteligência artificial, tais como Adaboost, Naive Bayes, Random Forest, Support Vector Machine (SVM), Neural Networks e CN2 Rule Induction. Após o cálculo dos picos dos sinais, a aplicação dos métodos foi feita com base em 15 características de cada sensor, tais como média, desvio padrão, variância, máximo, mínimo e mediana do sinal, cinco maiores distâncias entre os picos mais elevados, e média, desvio padrão, variância e mediana dos picos. Os métodos de inteligência artificial foram aplicados com a framework Orange. Para a validação dos modelos utilizados foi aplicada Stratified 10-fold Cross-validation.

RESULTADOS:

Os resultados reportados pelos diferentes métodos demonstraram que o método de Neural Networks apresentou uma eficácia de 90.14%, um F1-score de 90.13%, uma precisão de 90.18% e um Recall de 90.14%. Por sua vez, o método Random Forest reportou uma eficácia de 90.40%, um F1-score de 90.40%, uma precisão de 90.44% e um Recall de 90.40%. Seguidamente, o método Naive Bayes apresentou uma eficácia de 80.71%, um F1-score de 80.08%, uma precisão de 80.54% e um Recall de 80.71%. De outro modo, o método CN2 rule inducer apresenta uma eficácia de 82.18%, um F1-score de 82.37%, uma precisão de 82.62% e um Recall de 82.18%. A seguir, o método Adaboost reporta uma eficácia de 86.28%, um F1-score de 86.24%, uma precisão de 86.21% e um Recall de 86.28%. Por fim, o método SVM apresenta uma eficácia de 61.73%, um F1-score de 60.59%, uma precisão de 64.03% e um Recall de 61.73%.

DISCUSSÃO:

Dos diferentes métodos apresentados, o método que apresenta melhores resultados é o método Random Forest, sendo que o segundo melhor método é o método Adaboost, mas que exige mais capacidade de processamento. Para a melhoria de resultados, a fusão de dados demonstrou-se eficaz com estes 2 sensores, mas deve ser utilizado um conjunto de dados maior para colmatar alguns problemas no reconhecimento devido à variedade de dados.

CONCLUSÃO:

A fusão de dados do acelerómetro e magnetómetro em dispositivos móveis desempenha um papel fundamental na deteção precisa e versátil de atividades físicas. Essa abordagem melhora a qualidade das informações coletadas, permite análises mais avançadas e fornece uma base sólida para aplicações relacionadas à saúde, bem-estar e monitorização de atividades físicas.

Palavras-chave: Atividades de vida diária, Acelerómetro e Magnetómetro, Inteligência artificial, Saúde e Exercício físico, Sensores, Fusão e Classificação e Processamento de Dados

ABSTRACT

INTRODUCTION:

The detection of physical activities through the fusion of accelerometer and magnetometer data from mobile devices is of great importance in various applications such as health monitoring, fitness tracking, and movement analysis. The objective of this study is to merge data related to five physical activities, such as going up stairs, down stairs, walking, standing still, and running, using data acquired with the accelerometer and magnetometer in 5-second stretches for the extraction of characteristics of the captured signals and identification of different activities using artificial intelligence methods.

METHODS:

The architecture for the analysis consists of several phases, such as data acquisition, data processing, data cleaning, feature extraction, fusion of the processed data, and application of artificial intelligence methods, such as Adaboost, Naive Bayes, Random Forest, Support Vector Machine (SVM), Neural Networks and CN2 Rule Induction. After calculating the peaks of the signals, the methods were applied based on 15 characteristics of each sensor, such as mean, standard deviation, variance, maximum, minimum, and median of the raw signal, five greatest distances between the highest peaks, and mean, standard deviation, variance and median of the peaks. Artificial intelligence methods were applied with the Orange framework. Stratified 10-fold Cross-validation was applied to validate the models used.

RESULTS:

The results reported by the different methods showed that the Neural Networks method presented an efficiency of 90.14%, an F1-score of 90.13%, a precision of 90.18%, and a Recall of 90.14%. In

turn, the Random Forest method reported an efficiency of 90.40%, an F1-score of 90.40%, a precision of 90.44%, and a Recall of 90.40%. Then, the Naive Bayes method presented an efficiency of 80.71%, an F1-score of 80.08%, a precision of 80.54%, and a Recall of 80.71%. Otherwise, the CN2 rule inducer method presents an efficiency of 82.18%, an F1-score of 82.37%, a precision of 82.62%, and a Recall of 82.18%. Next, the Adaboost method reports an effectiveness of 86.28%, an F1-score of 86.24%, an accuracy of 86.21%, and a recall of 86.28%. Finally, the SVM method presents an efficiency of 61.73%, an F1-score of 60.59%, a precision of 64.03%, and a Recall of 61.73%.

DISCUSSION:

Thus, of the different methods presented, the method that presents the best results is the Random Forest method, and the second best method is the Adaboost method, but it requires more processing capacity. Data fusion proved effective with these 2 sensors to improve results. Still, a larger dataset should be used to overcome some problems in recognition due to the variety of data.

CONCLUSION:

In summary, the fusion of accelerometer and magnetometer data in mobile devices plays a key role in the accurate and versatile detection of physical activities. This approach improves the quality of collected information, allows for more advanced analysis, and provides a solid foundation for applications related to health, wellness, and physical activity monitoring.

Keywords: Activities of Daily Living, Accelerometer and Magnetometer, Artificial Intelligence, Health and Physical Exercise, Sensors, Data Fusion and Classification and Data Processing.