

Một phương pháp xây dựng hệ thống nhận dạng hành vi của người trong thời gian thực dựa trên các thuật toán học máy

Nguyễn Quang Huy¹, Trần Đức Nghĩa^{1,*}, Đào Tô Hiệu², Trần Đức Tân², Vũ Thị Thương³, Đỗ Xuân Trung⁴

¹ Viện Công nghệ thông tin, Viện Hàn lâm Khoa học và Công nghệ Việt Nam, Hà Nội

² Trường Đại học Phenikaa, Hà Nội

³ Đại học Phương Đông, Hà Nội

⁴ Đại học Kinh Bắc, Bắc Ninh

Tác giả liên hệ: Trần Đức Nghĩa, Email: nghiatd@ioit.ac.vn

Ngày nhận bài: 31/08/2022, ngày sửa chữa: 19/11/2022, ngày duyệt đăng: 25/11/2022

Định danh DOI: 10.32913/mic-ict-research-vn.v2022.n2.1137

Tóm tắt: Một trong những vấn đề quan trọng trong hệ thống nhận dạng hành vi của người (Human Activity Recognition – HAR) đó là giá thành, tốc độ và độ chính xác. Cùng với sự phát triển của các thiết bị di động, các bộ vi xử lý ngày càng hiện đại đi cùng với việc tích hợp nhiều cảm biến khác nhau bao gồm cả gia tốc kế đã giúp việc nhận dạng hành vi người trở nên dễ dàng và nhanh chóng hơn. Tuy nhiên, độ chính xác của việc phân loại hành vi dựa trên cảm biến gia tốc còn phụ thuộc rất nhiều yếu tố khác nhau dẫn đến kết quả có thể có sự sai lệch. Bằng nhiều thử nghiệm khác nhau, chúng tôi nhận thấy rằng việc lựa chọn các thuộc tính tối ưu có quan hệ quyết định tới hiệu suất của việc phân loại. Trong bài báo này, chúng tôi đề xuất một bộ thuộc tính đơn giản nhưng cho kết quả rất khả quan với độ chính xác tới 99%. Chúng tôi đã thực nghiệm và so sánh với một vài thuật toán phân loại khác nhau trên tập dữ liệu thu thập từ một số tình nguyện viên.

Từ khóa: Phân loại, cảm biến gia tốc, nhận dạng hành vi.

Title: A Method of Building a Real-time Human Behavior Recognition System based on Machine Learning Algorithms

Abstract: One of the key issues in Human Activity Recognition (HAR) systems is cost, speed, and accuracy. Along with the development of mobile devices, integration of various sensors, including accelerometers, has made human behavior recognition easier and faster. However, the accuracy of the behavior classification based on the accelerometer depends on many factors, leading to misleading results. In various tests, we found that the selection of optimal attributes has a decisive relationship to performing the classifier. In this paper, we propose a simple set of attributes but give very satisfactory results with 99% accuracy. We have tested and compared with a few different classification algorithms on a dataset collected from several volunteers.

Keywords: Classification, acceleration sensor, activity recognition

I. GIỚI THIỆU

Bài toán nhận dạng hoạt động người nói chung và nhận dạng hoạt động dựa trên cảm biến gia tốc nói riêng đang chứng tỏ được tầm quan trọng của nó với nhiều ứng dụng trong các lĩnh vực như nông nghiệp, y tế, công nghiệp, an ninh. [1-3]. Tuy nhiên, dù ở lĩnh vực nào thì việc thu thập dữ liệu cũng là yếu tố hết sức quan trọng. Ngày nay các thiết bị cảm biến được tích hợp nhiều trong các thiết bị di động để theo dõi các chỉ số khác nhau. Chẳng hạn như điện thoại thông minh không chỉ là thiết bị giao tiếp thông

thường mà còn có thể thu nhận nhiều tín hiệu môi trường từ các cảm biến bên trong nó [4]. Một trong số đó, gia tốc kế là cảm biến được sử dụng thường xuyên nhất cho việc nhận dạng hoạt động vì khả năng mang lại độ chính xác cao với năng lượng sử dụng thấp [5]. Với ưu điểm như vậy, gia tốc kế đã được nghiên cứu để thu thập dữ liệu từ nhiều vị trí khác nhau như chân [6], cổ tay [7], cánh tay [8], thắt lưng [9]. Ngoài ra, nhiều nghiên cứu đã sử dụng kết hợp cùng lúc nhiều cảm biến khác nhau để có thể phân loại được nhiều hành động hơn. Muhammad Shoaib cùng cộng sự [10] đã chứng minh rằng việc kết hợp con quay

hồi chuyển, từ kế và gia tốc kế có tác dụng tương hỗ làm cải thiện khả năng nhận dạng. Lei Gao và nhóm của mình trong công bố [11] đã nghiên cứu phân loại 8 hành động với bốn cảm biến gia tốc đặt ở bốn vị trí khác nhau là ngực, dưới cánh tay trái, eo và đùi. Mặc dù phương pháp đa cảm biến này có ưu điểm là gia tăng độ chính xác và khả năng nhận dạng được nhiều hành vi khác nhau, nhưng chúng vẫn có nhược điểm như giá thành thiết bị cao, tiêu hao nhiều năng lượng và hơn cả là gây khó chịu cho người mang nó, nhất là trong thời gian theo dõi dài. Trong phạm vi bài báo này, chúng tôi sử dụng mô hình nhận dạng dựa trên hành vi. So với các mô hình khác như mô hình hóa dựa trên vector (hoạt động, vị trí), mô hình hóa dựa trên vị trí, mô hình nhận dạng dựa trên hành vi đã được chứng minh đạt được độ chính xác cao nhất và ít tốn thời gian nhất, có thể xác định hiệu quả hành vi của con người [12]. Ngoài ra, các hành động cũng được giới hạn trong đời sống hàng ngày như đi lại, đứng, ngồi, nằm. Việc giới hạn này nhằm đưa ra một giải pháp xử lý tối ưu cho các thiết bị phần cứng vốn giới hạn ở khả năng xử lý và tính di động mà chúng tôi có. Do đó, bài báo này đề xuất sử dụng cảm biến gia tốc trên điện thoại thông minh đeo ở thắt lưng, thực hiện các thuật toán nhẹ về tính toán để nhận dạng các hoạt động cơ bản hàng ngày của con người. Phương pháp được đề xuất sử dụng một tập các thuộc tính tối thiểu để hệ thống có thể nhận dạng trong thời gian thực nhưng vẫn cho kết quả nhận dạng tốt.

II. PHƯƠNG PHÁP NGHIÊN CỨU


1. Mô hình nhận dạng

Kiến trúc của mô hình chúng tôi sử dụng để nhận dạng hoạt động người được minh họa trong Hình 1. Nó bao gồm ba thành phần chính:

(1) *Thu thập dữ liệu*: thu thập các tín hiệu thô từ cảm biến gia tốc trên điện thoại thông minh của người dùng (yêu cầu điện thoại có cảm biến gia tốc ba chiều và đã được cài đặt ứng dụng thu thập dữ liệu). Dữ liệu thu được là dữ liệu gia tốc theo ba trục X, Y, Z được tiền xử lý thành luồng dữ liệu.

(2) *Trích chọn các đặc trưng*: Luồng dữ liệu ở trên được phân tách bằng cửa sổ trượt để lấy một số dữ liệu chuỗi trong thời gian ngắn. Sau đó dữ liệu này được đưa vào bộ trích chọn các đặc trưng và chọn lọc để đưa vào bộ phân loại.

(3) *Phân loại hành động*: Trong phần này, bộ phân loại được huấn luyện để xây dựng mô hình phân loại hành vi dựa trên các thuật toán học máy.



Hình 1. Mô hình hệ thống nhận dạng hành vi người

2. Thu thập dữ liệu


Để thu thập bộ dữ liệu hoạt động, chúng tôi sử dụng điện thoại thông minh Android (Note10 Lite) có cài đặt ứng dụng Sensor Data Collector ghi lại dữ liệu từ gia tốc kế. Ba tình nguyện viên tham gia nghiên cứu này là người lớn có độ tuổi, chiều cao và cân nặng khác nhau. Mỗi người thực hiện các hành vi cơ bản trong cuộc sống hàng ngày là đi, đứng, nằm, ngồi một cách tự nhiên. Trong khi hoạt động, điện thoại được gắn cố định trên thắt lưng của mỗi người. Quá trình thu thập dữ liệu, nếu điện thoại ở trạng thái sử dụng màn hình hoặc nhận cuộc gọi, ứng dụng sẽ tạm ngừng việc thu thập. Số lượng dữ liệu thu được trong một giây phụ thuộc vào tần số lấy mẫu của thiết bị. Chúng tôi cài đặt tần số 1Hz cho cảm biến gia tốc để ghi lại dữ liệu hoạt động. Một số nghiên cứu gần đây cũng chứng minh rằng các nhiệm vụ phân loại đơn giản có thể được tiến hành hiệu quả ở tần số lấy mẫu và độ phân giải thấp, làm tăng tuổi thọ pin của thiết bị [13, 14]. Bộ dữ liệu thực nghiệm này được thể hiện ở Bảng I.

Bảng I
SỐ LƯỢNG THỬ NGHIỆM

Hoạt động	Số lượng phục vụ huấn luyện mô hình	Số lượng kiểm thử	Tổng
Nằm	11035	7430	15765
Ngồi	7178	3076	10254
Đứng	6709	2875	9584
Đi bộ	8253	3537	11790
Tổng	33175	14218	47393

Hình 2 thể hiện dữ liệu thô từ các cảm biến tương ứng với mỗi hoạt động khác nhau. Đối với các hoạt động tĩnh (nằm, ngồi, đứng), chúng tôi nhận thấy rằng không có sự giao nhau giữa các trục, do các cảm biến có xu hướng ổn định hơn các hoạt động khác. Trong khi đó, với các hoạt động di chuyển, dễ dàng nhận thấy sự chồng chéo các chỉ

số của cảm biến. Điều đó là bình thường và chứng tỏ là các cảm biến đang hoạt động tốt.



Hình 2. Dữ liệu gia tốc của các hoạt động: (Lying) – Nằm, (Standing) – Đứng, (Sitting) – Ngồi, (Normal Walking) – Di chuyển

3. Phân đoạn dữ liệu

Dữ liệu thu được từ cảm biến gia tốc là các dữ liệu thô có bản chất là các dao động theo thời gian. Các mô hình phân loại không thể được áp dụng trực tiếp trên các dữ liệu thô này. Nguyên nhân là do một hoạt động có thể kéo dài vài giây hoặc hơn nữa, nên một điểm dữ liệu riêng lẻ không thể chứa đầy đủ thông tin mô tả cho hoạt động đã thực hiện. Phân đoạn là quá trình nhóm dữ liệu cảm biến

thô của chuỗi thời gian liên tục thành các phần có thể quản lý được chứa thông tin mô tả một hoạt động [15]. Trong đó, phương pháp phân đoạn bằng cửa sổ thời gian đã được chứng minh là cho kết quả tốt nhất với việc nhận dạng các hoạt động thường ngày của con người [16].

Số lượng dữ liệu mẫu trong một phân đoạn hoặc cửa sổ phụ thuộc vào độ dài của cửa sổ được xác định trước. Việc lựa chọn tham số cửa sổ thời gian phù hợp cũng có hai cách tiếp cận. Cách thứ nhất là thu thập luồng dữ liệu theo kích thước cửa sổ thời gian cố định. Cách thứ hai là cửa sổ thời gian chồng chéo (hay cửa sổ trượt), tức là dữ liệu cửa sổ trước đó được chồng lên dữ liệu của cửa sổ hiện tại theo tỷ lệ phần trăm được xác định trước [15]. Chúng tôi lựa chọn sử dụng phương pháp cửa sổ trượt bởi đây là phương pháp phù hợp cho việc nhận dạng các hành động động và tĩnh trong thời gian thực [17]. Để lựa chọn độ dài cửa sổ tối ưu, chúng tôi đã tiến hành thử nghiệm với nhiều kích thước khác nhau (1s – 10s) với các khoảng chồng chéo (0% - 95%). Chúng tôi nhận thấy nếu độ dài cửa sổ quá ngắn thì sẽ không đủ thông tin để mô tả các hoạt động. Ngược lại, nếu kích thước của cửa sổ quá lớn, dữ liệu có thể bị nhiễu bởi trong thời gian đó đối tượng có thể đã thay đổi các hoạt động khác nhau. Như vậy, không có độ dài cửa sổ nào là thích hợp cho mọi tình huống hoạt động của con người. Tuy nhiên, trong thực nghiệm mà chúng tôi tiến hành là nhận dạng các hoạt động cơ bản hàng ngày với thời gian thực, chúng tôi lựa chọn độ dài cửa sổ là 3s với khoảng chồng chéo là 50%.

4. Trích chọn đặc trưng

Dữ liệu thô từ cảm biến có thể phân tích thành rất nhiều các đặc trưng khác nhau. Trích chọn đặc trưng là một kỹ thuật trong miền chuyên biệt (như thời gian hoặc tần số) định nghĩa một đặc trưng mới từ dữ liệu thô nhằm giảm độ phức tạp tính toán và nâng cao quy trình nhận dạng [18, p. 193]. Trước đây, nhiều kỹ thuật trích chọn đặc trưng phức tạp như phân tích thành phần chính (PCA) [19], phân tích phân biệt tuyến tính (LDA) [20] và các đặc trưng wavelet [21] đã được sử dụng; tuy nhiên, chúng rất tốn kém về mặt tính toán và khó thực hiện. Một số nghiên cứu [22, 23] chỉ ra rằng các bộ đặc trưng đơn giản vẫn có thể đạt được độ chính xác cao.

Đối với bài toán thực nghiệm này, chúng tôi sử dụng năm đặc trưng cơ bản là Trung bình (*mean*), Độ lệch chuẩn (*standard deviation*), Giá trị hiệu dụng (*RMS*), Trung vị (*median*) và Khoảng biến thiên (*range*). Các đặc trưng này tính toán như trong Bảng II.

5. Phân loại hành động

Chúng tôi sử dụng các bộ phân loại có sẵn trong thư viện Sklearn để thực hiện phân loại hành vi. Bên cạnh độ chính

xác cao và thời gian huấn luyện ngắn, các bộ phân loại còn phải đáp ứng các yêu cầu về thời gian thực. Tập hợp các đặc trưng sẽ được đưa vào quá trình huấn luyện và phân loại. Các phương pháp phân loại được sử dụng bao gồm: Cây quyết định tăng cường Gradient, Máy hỗ trợ vector, Rừng ngẫu nhiên, KNN (k-Nearest Neighbor). Đây cũng là các thuật toán phân lớp được sử dụng rộng rãi trong học máy và phân tích dữ liệu.

Bảng II
TRÍCH CHỌN ĐẶC TRƯNG

Đặc trưng	Định nghĩa
Trung bình (mean)	$m = \frac{1}{N} \sum_{i=1}^N x_i$ (1)
Độ lệch chuẩn (standard deviation)	$\sigma(X_j) = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$ (2)
Giá trị hiệu dụng (RMS)	$RMS_X = \frac{1}{N} \sum_{i=1}^N x_i^2$ (3)
Trung vị (median)	$\frac{x_{[\#N/2]} + x_{[\#N/2+1]}}{2}$ (4)
Khoảng biến thiên (range)	$[\min_{i=1}^N \{x_i\}, \max_{i=1}^N \{x_i\}]$ (5)

Trong đó:

X_j là bản ghi dữ liệu thứ j của trục X

N là số lần lấy mẫu trong mỗi bản ghi

x_i là mẫu thứ i của bản ghi X_j

6. Phép đánh giá

Để xác định tính hiệu quả của thuật toán học máy, chúng tôi biểu diễn kết quả phân loại dưới dạng ma trận nhầm lẫn, với các phép thử được tính như sau:

$$accuracy = \frac{(TP + TN)}{(TP + FP + FN + TN)} \quad (6)$$

$$sensitivity = \frac{TP}{(TP + FN)} \quad (7)$$

$$precision = \frac{TP}{(TP + FP)} \quad (8)$$

Trong đó:

- TP (True Positive): Số lượng hoạt động được gán nhãn đúng so với quan sát.
- FN (False Negative): Số lượng hoạt động bị gán nhãn sai thành các hoạt động khác.
- FP (False Positive): Số lượng hoạt động khác bị gán nhãn sai thành hoạt động đang xem xét.
- TN (True Negative): Số lượng hoạt động khác được gán nhãn đúng so với quan sát.

III. KẾT QUẢ VÀ THẢO LUẬN

Kết quả chi tiết của việc phân loại hành vi được trình bày trong Bảng III. Thuật toán phân loại XGBoost cho kết quả tốt vượt trội so với các thuật toán còn lại. Trong bảng ma trận nhầm lẫn ở Bảng IV, hầu hết các mẫu thử nghiệm về hành vi được phân biệt rất tốt (4710/4710 mẫu thử hành động nằm, 3004/3069 mẫu thử hành động đứng, 2777/2843 mẫu thử hành động ngồi, 3561/3596 mẫu thử hành động đi). Nhưng cũng có thể thấy rằng có 95 mẫu được phân loại sai do nhầm lẫn giữa đứng và ngồi, trong khi giữa đứng và đi chỉ có 46 mẫu được phân loại sai, và giữa các hành động khác thì còn thấp hơn.

Bảng III
KẾT QUẢ THỰC HIỆN PHÂN LOẠI HÀNH VI

Thuật toán	Kết quả		
	Accuracy	Sensitivity	Precision
Decision Tree (DT)	91.5%	91%	92%
Gradient Boosted Decision Tree (GBDT)	93%	93%	94%
Support Vector Machine (SVM)	94%	94%	94%
Random Forest (RF)	94%	93%	94%
k-Nearest Neighbor (KNN)	95%	95%	96%
XGBoost	99%	99%	99%

Bảng IV
MA TRẬN NHẦM LẦN

Hành vi quan sát được	Hành vi được dự đoán				Tổng
	Nằm	Đứng	Ngồi	Đi	
Nằm	4710	0	0	0	4710
Đứng	0	3004	47	18	3069
Ngồi	0	48	2777	18	2843
Đi	0	28	7	3561	3596
Tổng	4710	3080	2831	3597	14218

Trong cuộc sống hiện đại ngày nay, nhu cầu chăm sóc sức khỏe ngày càng được chú trọng, đặc biệt là người bệnh và người già. Các ứng dụng nhận dạng hoạt động nâng cao được tích hợp để hỗ trợ các hoạt động của con người. Trong đó, việc lựa chọn các đặc trưng đóng một vai trò quan trọng ảnh hưởng tới độ chính xác và tốc độ nhận dạng. Đã có nhiều nghiên cứu lựa chọn khá nhiều đặc điểm để nâng cao tỷ lệ nhận diện hoạt động như [24, 25] sử dụng 43 đặc trưng; [26] sử dụng 64 đặc trưng. Nghiên cứu hiện tại chỉ

sử dụng một bộ đơn giản và hiệu quả gồm năm đặc trưng thống kê và kích thước cửa sổ trượt tối ưu cho hiệu quả nhận dạng tương đối tốt.

Hệ thống của chúng tôi có ưu điểm là độ chính xác cao và có thể chạy trong thời gian thực, do đó có thể được áp dụng cho bệnh nhân hoặc người già. Tuy nhiên nhược điểm dễ nhận thấy đó là hệ thống không thể áp dụng chung cho nhiều đối tượng sử dụng, đặc biệt là những người có cường độ hoạt động cao. Bên cạnh đó, một hạn chế rõ ràng của thiết bị là cần phải có smartphone mang theo và đặt cố định ở tại một vị trí để đảm bảo thuật toán nhận dạng chính xác.

IV. KẾT LUẬN

Kết quả thực nghiệm cho thấy mô hình nhận dạng sử dụng các thuật toán phân loại phổ biến và tập đặc trưng của chúng tôi cho kết quả rất tốt với các hoạt động thường ngày của con người. Việc đơn giản hoá bộ đặc trưng và lựa chọn kích thước cửa sổ tối ưu từ việc phân tích đặc điểm dữ liệu có thể làm cải thiện tốc độ nhận dạng mà vẫn đảm bảo độ chính xác. Ngoài ra, việc lựa chọn một thuật toán phân loại thích hợp cũng ảnh hưởng rõ rệt tới kết quả nhận dạng. Đối với mô hình thử nghiệm của chúng tôi, thuật toán XGBoost giúp cải thiện độ chính xác hơn so với Decision Tree, Gradient Boosted Tree, SVM, RF, KNN. Tuy nhiên, hành vi của con người không chỉ là tự nhiên và tự phát, mà con người có thể thực hiện một số hoạt động cùng một lúc, hoặc thậm chí thực hiện một số hoạt động không liên quan. Đây cũng là thách thức lớn trong bài toán nhận dạng hành động với thời gian thực. Trong tương lai, chúng tôi tiếp tục phát triển hệ thống của mình để có thể dự đoán và xác định các hoạt động đồng thời, hỗ trợ ứng dụng cho các hoàn cảnh sử dụng phức tạp hơn, hướng tới các ứng dụng không chỉ gắn trên người [27], sử dụng những cảm biến nhỏ gọn hơn [28, 29].

LỜI CẢM ƠN

Trần Đức Nghĩa được tài trợ bởi Chương trình học bổng sau tiến sĩ trong nước của Quỹ Đổi mới sáng tạo Vingroup (VINIF), mã số VINIF.2022.STS.38.

Bài báo được hỗ trợ bởi Viện Công nghệ thông tin (IOIT), Viện Hàn lâm Khoa học và Công nghệ Việt Nam (VAST), mã đề tài CSCL02.01/22-23.

TÀI LIỆU THAM KHẢO

- [1] N. F. Ghazali, N. Shahar, N. A. Rahmad, N. A. J. Sufri, M. A. As'ari, and H. F. M. Latif, "Common sport activity recognition using inertial sensor," in *2018 IEEE 14th International Colloquium on Signal Processing & Its Applications (CSPA)*, Batu Feringghi, Mar. 2018, pp. 67–71. doi: 10.1109/CSPA.2018.8368687.
- [2] F. Hussain, F. Hussain, M. Ehatisham-ul-Haq, and M. A. Azam, "Activity-Aware Fall Detection and Recognition Based on Wearable Sensors," *IEEE Sensors Journal*, vol. 19, no. 12, pp. 4528–4536, Jun. 2019, doi: 10.1109/JSEN.2019.2898891.
- [3] A. Vysocky and P. Novak, "HUMAN – ROBOT COLLABORATION IN INDUSTRY," *MM Sci. J.*, vol. 2016, no. 02, pp. 903–906, Jun. 2016, doi: 10.17973/MMSJ.2016_06_201611.
- [4] Haibo Ye et al., "FTrack: Infrastructure-free floor localization via mobile phone sensing," in *2012 IEEE International Conference on Pervasive Computing and Communications*, Lugano, Switzerland, Mar. 2012, pp. 2–10. doi: 10.1109/PerCom.2012.6199843.
- [5] W. T. D. Souza and K. R., "Human Activity Recognition Using Accelerometer and Gyroscope Sensors," *Int. J. Eng. Technol.*, vol. 9, no. 2, pp. 1171–1179, Apr. 2017, doi: 10.21817/ijet/2017/v9i2/170902134.
- [6] B. H. Dobkin, X. Xu, M. Batalin, S. Thomas, and W. Kaiser, "Reliability and Validity of Bilateral Ankle Accelerometer Algorithms for Activity Recognition and Walking Speed After Stroke," *Stroke*, vol. 42, no. 8, pp. 2246–2250, Aug. 2011, doi: 10.1161/STROKEAHA.110.611095.
- [7] W.-Y. Lin, V. Verma, M.-Y. Lee, and C.-S. Lai, "Activity Monitoring with a Wrist-Worn, Accelerometer-Based Device," *Micromachines*, vol. 9, no. 9, p. 450, Sep. 2018, doi: 10.3390/mi9090450.
- [8] L. Billiet, T. Swinnen, K. de Vlam, R. Westhovens, and S. Van Huffel, "Recognition of Physical Activities from a Single Arm-Worn Accelerometer: A Multiway Approach," *Informatics*, vol. 5, no. 2, p. 20, Apr. 2018, doi: 10.3390/informatics5020020.
- [9] Y. Zhu, J. Yu, F. Hu, Z. Li, and Z. Ling, "Human activity recognition via smart-belt in wireless body area networks," *Int. J. Distrib. Sens. Netw.*, vol. 15, no. 5, p. 155014771984935, May 2019, doi: 10.1177/1550147719849357.
- [10] M. Shoaib, S. Bosch, O. Incel, H. Scholten, and P. Havinga, "Fusion of Smartphone Motion Sensors for Physical Activity Recognition," *Sensors*, vol. 14, no. 6, pp. 10146–10176, Jun. 2014, doi: 10.3390/s140610146.
- [11] L. Gao, A. K. Bourke, and J. Nelson, "Evaluation of accelerometer based multi-sensor versus single-sensor activity recognition systems," *Med. Eng. Phys.*, vol. 36, no. 6, pp. 779–785, Jun. 2014, doi: 10.1016/j.medengphys.2014.02.012.
- [12] L. Fan, Z. Wang, and H. Wang, "Human Activity Recognition Model Based on Decision Tree," in *2013 International Conference on Advanced Cloud and Big Data*, Nanjing, China, Dec. 2013, pp. 64–68. doi: 10.1109/CBD.2013.19.
- [13] A. Khan, N. Hammerla, S. Mellor, and T. Plötz, "Optimising sampling rates for accelerometer-based human activity recognition," *Pattern Recognit. Lett.*, vol. 73, pp. 33–40, Apr. 2016, doi: 10.1016/j.patrec.2016.01.001.
- [14] X. Fafoutis, L. Marchegiani, A. Elsts, J. Pope, R. Piechocki, and I. Craddock, "Extending the battery lifetime of wearable sensors with embedded machine learning," in *2018 IEEE 4th World Forum on Internet of Things (WF-IoT)*, Singapore, Feb. 2018, pp. 269–274. doi: 10.1109/WF-IoT.2018.8355116.
- [15] S. Bashir, D. Doolan, and A. Petrovski, "The Effect of Window Length on Accuracy of Smartphone-Based Activity Recognition," *IAENG Int. J. Comput. Sci.*, vol. 43, pp. 126–136, Feb. 2016.
- [16] B. Quigley, M. Donnelly, G. Moore, and L. Galway, "A Comparative Analysis of Windowing Approaches in Dense Sensing Environments," *Proceedings*, vol. 2, no. 19, p. 1245, Oct. 2018, doi: 10.3390/proceedings2191245.
- [17] O. Banos, J.-M. Galvez, M. Damas, H. Pomares, and I.

- Rojas, "Window Size Impact in Human Activity Recognition," *Sensors*, vol. 14, no. 4, pp. 6474–6499, Apr. 2014, doi: 10.3390/s140406474.
- [18] G. Alor-Hernández and R. Valencia-García, *Current Trends on Knowledge-Based Systems*. Springer International Publishing, 2017. [Online]. Available: <https://books.google.com.vn/books?id=JzFXDgAAQBAJ>
- [19] M. B. Abidine and B. Fergani, "Evaluating a new classification method using PCA to human activity recognition," in *2013 International Conference on Computer Medical Applications (ICCMA)*, Sousse, Jan. 2013, pp. 1–4. doi: 10.1109/ICCMA.2013.6506158.
- [20] T.-P. Kao, C.-W. Lin, and J.-S. Wang, "Development of a portable activity detector for daily activity recognition," in *2009 IEEE International Symposium on Industrial Electronics*, Seoul, South Korea, Jul. 2009, pp. 115–120. doi: 10.1109/ISIE.2009.5222001.
- [21] S. J. Preece, J. Y. Goulermas, L. P. J. Kenney, and D. Howard, "A Comparison of Feature Extraction Methods for the Classification of Dynamic Activities From Accelerometer Data," *IEEE Trans. Biomed. Eng.*, vol. 56, no. 3, pp. 871–879, Mar. 2009, doi: 10.1109/TBME.2008.2006190.
- [22] M. B. Dehkordi, A. Zaraki, and R. Setchi, "Feature extraction and feature selection in smartphone-based activity recognition," *Procedia Comput. Sci.*, vol. 176, pp. 2655–2664, 2020, doi: 10.1016/j.procs.2020.09.301.
- [23] M. Zhang and A. A. Sawchuk, "A bag-of-features-based framework for human activity representation and recognition," in *Proceedings of the 2011 international workshop on Situation activity & goal awareness - SAGAware '11*, Beijing, China, 2011, p. 51. doi: 10.1145/2030045.2030058.
- [24] J. R. Kwapisz, G. M. Weiss, and S. A. Moore, "Activity recognition using cell phone accelerometers," *ACM SIGKDD Explor. Newsl.*, vol. 12, no. 2, pp. 74–82, Mar. 2011, doi: 10.1145/1964897.1964918.
- [25] C. Catal, S. Tufekci, E. Pirmit, and G. Kocabag, "On the use of ensemble of classifiers for accelerometer-based activity recognition," *Appl. Soft Comput.*, vol. 37, pp. 1018–1022, Dec. 2015, doi: 10.1016/j.asoc.2015.01.025.
- [26] G. Vavoulas, C. Chatzaki, T. Malliotakis, M. Padiaditis, and M. Tsiknakis, "The MobiAct Dataset: Recognition of Activities of Daily Living using Smartphones," in *Proceedings of the International Conference on Information and Communication Technologies for Ageing Well and e-Health*, Rome, Italy, 2016, pp. 143–151. doi: 10.5220/0005792401430151.
- [27] Q.-T. Hoang, P. C. Phi Khanh, B. T. Ninh, C. T. Phuong Dung, and T. D. Tran, "Cow Behavior Monitoring Using a Multidimensional Acceleration Sensor and Multiclass SVM," *Int. J. Mach. Learn. Networked Collab. Eng.*, vol. 2, no. 3, pp. 110–118, Sep. 2018, doi: 10.30991/IJML-NCE.2018v02i03.003.
- [28] T. D. Tran, D. V. Dao, T. T. Bui, L. T. Nguyen, T. P. Nguyen, and Sugiyama Susumu, "Optimum design considerations for a 3-DOF micro accelerometer using nanoscale piezoresistors," in *2008 3rd IEEE International Conference on Nano/Micro Engineered and Molecular Systems*, Sanya, China, 2008, pp. 770–773. doi: 10.1109/NEMS.2008.4484440.
- [29] T.-H. Dao, H.-Y. Hoang, V.-N. Hoang, D.-T. Tran, and D.-N. Tran, "Human Activity Recognition System For Moderate Performance Microcontroller Using Accelerometer Data And Random Forest Algorithm," *EAI Endorsed Trans. Ind. Neww. Intell. Syst.*, vol. 9, no. 4, p. e4, Nov. 2022, doi: 10.4108/ee-tinis.v9i4.2571.

SƠ LƯỢC VỀ TÁC GIẢ



Email: nghuy@ioit.ac.vn

Nguyễn Quang Huy tốt nghiệp Thạc sĩ ngành Công nghệ Thông tin năm 2017 tại Học viện Công nghệ Bưu chính Viễn thông. Hiện là nghiên cứu viên của Viện Công nghệ Thông tin - Viện Hàn lâm Khoa học và Công nghệ Việt Nam (VAST).
Lĩnh vực nghiên cứu: phân tích dữ liệu, mạng cảm biến không dây và các ứng dụng.



Email: nghiatd@ioit.ac.vn

Trần Đức Nghĩa tốt nghiệp Tiến sĩ Công nghệ thông tin tại trường Université Paris Descartes, Cộng hòa Pháp năm 2018. Hiện công tác tại phòng Tin học quản lý, viện Công nghệ thông tin, VAST.
Lĩnh vực nghiên cứu: phổ EPR, Internet vạn vật, ứng dụng học máy, cảm biến gia tốc.



Email: hieu.daoto@phenikaa-uni.edu.vn

Đào Tô Hiệu tốt nghiệp Thạc sĩ ngành Kỹ thuật Điện tử năm 2017 tại Trường Đại học Bách Khoa Hà Nội.
Hiện là giảng viên Khoa Điện-Điện tử, Trường Đại học Phenikaa.

Lĩnh vực nghiên cứu: các thuật toán học máy nhẹ ứng dụng trên vi điều khiển hiệu năng thấp, thiết bị hỗ trợ lính cứu hỏa mang trên người, mạng cảm biến, ứng dụng đo lường giám sát IOT.



Trần Đức Tân tốt nghiệp Tiến sĩ ngành Kỹ thuật điện tử năm 2010 tại Trường Đại học Công nghệ, Đại học Quốc Gia Hà Nội.
Hiện là giảng viên, Phó trưởng Khoa Điện – Điện tử, Trường Đại học PHENIKAA.
Lĩnh vực nghiên cứu: xử lý tín hiệu, mạng cảm biến không dây và các ứng dụng.

Email: tan.tranduc@phenikaa-uni.edu.vn



Email: thuongvt@dhp.edu.vn

Vũ Thị Thương tốt nghiệp Thạc sĩ ngành Khoa học máy tính năm 2009 tại Học viện Kỹ thuật quân sự.
Hiện là giảng viên Khoa CNTT và Truyền thông, Trường Đại học Phương Đông.

Lĩnh vực nghiên cứu: Các phương pháp học máy nhằm cải thiện việc đo tín hiệu, sử dụng cảm biến gia tốc và thuật toán học



Email: dotrung@ukb.edu.vn

Đỗ Xuân Trung tốt nghiệp Thạc sĩ ngành Kỹ thuật Điện tử năm 2014 tại viện Đại học Mở Hà Nội.

Hiện đang công tác tại Khoa CNTT - Điện tử Viễn thông, trường Đại học Kinh Bắc.
Lĩnh vực nghiên cứu: Xử lý tín hiệu và thông tin, thiết kế vi mạch và tích hợp hệ thống.