

HỌC VIỆN CÔNG NGHỆ BƯU CHÍNH VIỄN THÔNG



PHAN HỮU THẮNG

**NGHIÊN CỨU NHẬN DẠNG HOẠT ĐỘNG BẤT
THƯỜNG CỦA NGƯỜI BẰNG IOT**

LUẬN VĂN THẠC SĨ KỸ THUẬT
(Theo định hướng ứng dụng)

HÀ NỘI – 2020

HỌC VIỆN CÔNG NGHỆ BƯU CHÍNH VIỄN THÔNG



PHAN HỮU THẮNG

**NGHIÊN CỨU NHẬN DẠNG HOẠT ĐỘNG BẤT
THƯỜNG CỦA NGƯỜI BẰNG IOT**

CHUYÊN NGÀNH : KHOA HỌC MÁY TÍNH
MÃ SỐ: 8.48.01.01

LUẬN VĂN THẠC SĨ KỸ THUẬT
(Theo định hướng ứng dụng)

NGƯỜI HƯỚNG DẪN KHOA HỌC
PGS.TS. PHẠM VĂN CƯỜNG

HÀ NỘI – 2020

LỜI CAM ĐOAN

Tôi cam đoan đây là công trình nghiên cứu của riêng tôi. Nội dung của luận văn có tham khảo và sử dụng các tài liệu, thông tin được đăng tải trên những tạp chí và các trang web theo danh mục tài liệu tham khảo. Tất cả các tài liệu tham khảo đều có xuất xứ rõ ràng và được trích dẫn hợp pháp.

Tôi xin hoàn toàn chịu trách nhiệm và chịu mọi hình thức kỷ luật theo quy định cho lời cam đoan của mình.

Hà nội, ngày tháng năm 2020

Người cam đoan

Phan Hữu Thăng

LỜI CẢM ƠN

Lời đầu tiên, em xin bày tỏ sự cảm ơn chân thành đối với thầy giáo PGS.TS Phạm Văn Cường - Giáo viên hướng dẫn trực tiếp của tôi. Thầy đã giúp tôi tiếp cận những kiến thức về ứng dụng học máy vào bài toán phát hiện hoạt động bất thường sử dụng IoT trong suốt quá trình nghiên cứu và hoàn thiện luận văn thạc sĩ kỹ thuật.

Em xin gửi lời cảm ơn tới các thầy cô trong khoa Công nghệ Thông tin Học viện Bưu chính viễn thông đã hướng dẫn, chỉ bảo và tạo điều kiện cho chúng tôi học tập và nghiên cứu tại trường trong suốt thời gian qua.

Em xin gửi lời cảm ơn sự hỗ trợ từ đề tài nghiên cứu độc lập cấp quốc gia **“Nghiên cứu thiết kế, chế tạo hệ thống tự động trợ giúp theo dõi hô hấp và vận động bất thường dựa trên nền tảng Internet vạn vật (IoT-Internet of Things)”** mã số ĐTĐLCN-16/18.

Mặc dù đã cố gắng để hoàn thành luận văn nhưng chắc chắn sẽ không thể tránh khỏi những thiếu sót. Kính mong nhận được sự thông cảm và chỉ bảo của các quý thầy cô.

.

Hà Nội, Ngày 15/05/2020

Học viên

MỤC LỤC

LỜI CAM ĐOAN	i
LỜI CẢM ƠN	ii
DANH MỤC BẢNG	iv
DANH MỤC HÌNH	v
IMỞ ĐẦU	1
II. NỘI DUNG	5
CHƯƠNG 1:TỔNG QUAN VỀ PHÁT HIỆN VẬN ĐỘNG BẤT THƯỜNG	5
1.1 Giới thiệu	5
1.2 Các nghiên cứu trước đây về phát hiện hoạt động bất thường	8
1.3 Phạm vi và các giả định	16
CHƯƠNG 2: PHÁT HIỆN HOẠT ĐỘNG BẤT THƯỜNG CỦA CON NGƯỜI. 18	
2.1.Thiết kế vòng đeo tay thông minh, dây thắt lưng thông minh.....	18
2.2.Phân tích và xử lý dữ liệu cảm biến.....	22
2.3.Phát hiện hoạt động bất thường	26
2.3.1 Huấn luyện mô hình học máy	26
CHƯƠNG 3:THỰC NGHIỆM VÀ ĐÁNH GIÁ	34
3.1.Thu thập dữ liệu	34
3.2.Thử nghiệm và đánh giá	36
3.3. Kết quả	38
III. KẾT LUẬN	42
IV. DANH MỤC CÁC TÀI LIỆU THAM KHẢO.....	43

DANH MỤC BẢNG

Bảng 1-1 - Bảng ma trận lỗi.	13
Bảng 2-1 : Cấu trúc của một Packet	20
Bảng 2-2 : Cấu trúc một SampleData	20
Bảng 3-1 : Danh sách các hoạt động	35
Bảng 3-2 : Bảng ma trận confusion	36
Bảng 3-3: Mã trận lỗi giải pháp thứ nhất	39
Bảng 3-4 : Kết quả giải pháp thứ nhất	39
Bảng 3-5 : Mã trận lỗi giải pháp thứ nhất	40
Bảng 3-6 : Kết quả giải pháp thứ 2	41

DANH MỤC HÌNH

Hình 1-1. Loại cảm biến và vị trí gắn cảm biến [5]	9
Hình 1-2. Mô hình nhận dạng hoạt động bất thường của Jie Yin [5]	10
Hình 1-3. Xây dựng mô hình hoạt động bất thường [5]	12
Hình 1- 4 - Kết quả thực nghiệm Jie Yin	14
Hình 1-5 : Mô hình phát hiện hoạt động bất thường của Apurva Landge [12]	15
Hình 2-1 Kích thước cảm biến WAX3	18
Hình 2-2 hình dạng cảm biến WAX3	19
Hình 2-3: Vòng đeo tay thông minh	21
Hình 2-4 : Ví dụ hình ảnh phát hiện điểm bất thường bằng One Class SVM	27
Hình 2-5 : Mô hình huấn luyện mô hình học máy	27
Hình 2-6 : Mô hình huấn luyện mô hình học máy	30
Hình 2- 7 : Mô hình HMM cho hoạt động đi bộ các hướng.	31
Hình 2-8 : Mô hình HMM cho hoạt động Chạy chậm.	31
Hình 2-8 : Mô hình nhận dạng hoạt động bất thường	32
Hình 3-1: Bố trí, lắp đặt môi trường và thiết bị thu dữ liệu trong bộ CMDFALL	34

I. MỞ ĐẦU

1. Lý do chọn đề tài

Dân số thế giới đang già đi nhanh chóng. Theo thời gian, tỷ lệ người già trên tổng dân số tăng lên, và tiếp tục tăng, đặc biệt là ở các nước phát triển. Vì vậy, giúp người cao tuổi sống một cuộc sống tốt hơn là rất quan trọng và có lợi ích xã hội tuyệt vời. Mặc dù một số người lớn tuổi có lựa chọn đi nhà dưỡng lão, nhưng hầu hết trong số họ muốn ở trong nhà riêng của mình, nơi họ cảm thấy quen thuộc và thoải mái hơn. Vấn đề kinh phí hạn chế cho các dịch vụ y tế công cộng và sự thiếu hụt các y tá cũng là yếu tố thúc đẩy việc áp dụng mô hình người cao tuổi sống và được hỗ trợ tại nhà mình. Do đó, vấn đề dưỡng lão ở nhà đã trở thành một trong những vấn đề được nghiên cứu nhiều, đặc biệt là vấn đề phát hiện hoạt động bất thường. Người cao tuổi sống một mình trong nhà riêng của mình cần được chăm sóc khẩn cấp nhanh chóng, và trong những trường hợp xấu nhất, một số người đã được tìm thấy đã chết trong nhà của họ khi bị trượt ngã. Nếu như có một hệ thống giúp phát hiện một cách chính xác và cảnh báo những hoạt động bất thường của họ (như là trượt ngã, ngã từ trên giường xuống...) cho người thân hoặc những người dân xung quanh, thì có thể họ đã được cứu chữa một cách kịp thời.

Một vấn đề khác cũng rất được xã hội quan tâm đó là việc chăm sóc sức khỏe, theo dõi cho những người bệnh đặc biệt là những bệnh nhân bị rối loạn nhận thức, những bệnh nhân mắc các chứng như bệnh Parkinson hoặc bệnh Alzheimer. Những người này thường có những hoạt động bất thường gây nguy hiểm đến tính mạng như những bệnh nhân mắc bệnh Parkinson – đây là chứng bệnh gây gây thoái hóa hệ thần kinh trung ương gây ảnh hưởng đến tình trạng hoạt động, thăng bằng và kiểm soát cơ của bệnh nhân. Nếu như ngôi nhà nơi họ sống có những thiết bị thông minh giúp phát hiện và cảnh báo những hoạt động bất thường của họ thì họ sẽ có cơ hội sống tốt hơn và an toàn hơn trong chính ngôi nhà của mình.

Theo truyền thống, các phương pháp phát hiện hoạt động bất thường của con người sử dụng camera để có được dữ liệu về chuyển động toàn thân của con người. Tuy nhiên, có những vấn đề thách thức trong các phương pháp dựa trên thị giác máy tính, chẳng hạn như tính phức tạp về tính toán trong xử lý hình ảnh, tính thống nhất dữ liệu trong các điều kiện chiếu sáng khác nhau và sự xâm phạm quyền riêng tư của con người. Những vấn đề này làm cho việc triển khai thực tế các hệ thống dựa trên xử lý ảnh trở nên khó khăn.

Một phương pháp tốt được thay thế cho phương pháp xử lý ảnh đó là phương pháp sử dụng các cảm biến gắn trên các vật dụng tiện lợi đeo trên cơ thể con người như là vòng đeo tay hay dây thắt lưng để phát hiện các hoạt động bất thường của con người. Dữ liệu chuyển động của con người được các cảm biến thu thập ít hơn rất nhiều so với phương pháp sử dụng camera thu thập hình ảnh chuyển động. Một vấn đề nữa đó là sử dụng cảm biến thu thập dữ liệu chuyển động của con người đảm bảo quyền riêng tư.

Đồng hành cùng sự bùng nổ công nghệ thông tin, cách mạng công nghệ 4.0 trong những năm gần đây là sự ra đời của những giải pháp công nghệ áp dụng vào lĩnh vực y tế xã hội. Nhận thấy được những lợi ích mà hệ thống nhận dạng hoạt động bất thường của con người mang lại, luận văn đã chọn đề tài: ***“Nghiên cứu nhận dạng hoạt động bất thường của con người bằng IoT”***.

Bố cục luận văn bao gồm phần mở đầu, phần kết luận và các chương nội dung được tổ chức như sau:

- **Chương 1:** Tổng quan về các hoạt động bất thường. Nội dung chính của chương này là trình bày tổng quan về các hoạt động bất thường; trình bày ngắn gọn một số công trình nghiên cứu liên quan về công nghệ cảm biến trợ giúp nhận dạng và theo dõi hoạt động của con người. Từ đó đưa ra bài toán cần giải quyết trong luận văn.
- **Chương 2:** Nghiên cứu thiết kế các vật dụng tiện lợi gắn cảm biến. Chương này trình bày về thiết kế vòng đeo tay thông minh, dây thắt lưng

thông minh có gắn cảm biến gia tốc; Phương pháp phân tích và tiền xử lý dữ liệu cảm biến, và phương pháp phát hiện tần suất hoạt động bất thường của con người;

- **Chương 3:** Thực nghiệm và đánh giá. Nội dung chương 3 bao gồm các bước: thu thập dữ liệu về vận động của con người, các hoạt động bình thường và bất thường; đánh giá phương pháp phát hiện hoạt động bất thường của con người.

2. Tổng quan về vấn đề nghiên cứu

- Nghiên cứu của Jie Yin, Qiang Yang là “Sensor-Based Abnormal Human-Activity Detectio” [5]. Tác giả đã đề xuất phương pháp hai giai đoạn để phát hiện các hoạt động bất thường, được xây dựng dựa trên dữ liệu có sẵn của các hoạt động bình thường. Trong giai đoạn đầu tiên, tác giả xây dựng một mô hình học máy SVM chỉ dựa trên các hoạt động bình thường, có thể lọc ra các hoạt động có xác suất rất cao bình thường. Sau đó, các hoạt động đáng ngờ được chuyển sang giai đoạn thứ hai để phát hiện thêm. Trong giai đoạn thứ hai, tác giả thực hiện phân tích hồi quy phi tuyến hạt nhân (KNLR) để lấy được các mô hình hoạt động bất thường.
- Nghiên cứu của Nadezhda Sazonova, Raymond C. Browning, và Edward Sazonov[1]. Đó là nghiên cứu “Accurate Prediction of Energy Expenditure Using a Shoe-Based Activity Monitor” của Nadezhda Sazonova, Raymond C. Browning, và Edward Sazonov. Nghiên cứu này phát triển một thiết bị gắn trên giày được nhúng một gia tốc kế và một cảm biến áp suất ở đế giày cho việc dự đoán năng lượng calo tiêu thụ. Việc đầu tiên, dữ liệu thu được từ cảm biến gia tốc và cảm biến áp suất dùng để nhận dạng các hoạt động cụ thể như Sitting, Walking, Cycle. Nghiên cứu sử dụng thuật toán phân nhánh để ước lượng calo tiêu thụ và nhận dạng chính xác các tư thế và hoạt động. Nghiên cứu còn năng lượng calo tiêu thụ qua nhiệt lượng gián tiếp trên 16 người với tập 4 hoạt động nêu trên, để so sánh với kết quả ước lượng thu thập được mô hình sử dụng cảm biến gia tốc và cảm biến áp suất. Kết quả cho thấy, nếu có các dữ liệu áp lực dẫn đến độ chính xác tốt hơn dự đoán của năng lượng trong tư thế tĩnh như ngồi và đứng. Các hoạt động dựa trên mô hình phân

nhánh trong đó có những dự báo từ gia tốc và cảm biến áp lực (BACC-PS) đạt mức lỗi thấp nhất (ví dụ, gốc có nghĩa là lỗi bình phương (RMSE) = 0,69 METS) so với mô hình phân nhánh gia tốc chỉ dựa trên BACC(RMSE = 0,77 METS) và mô hình không phân nhánh (RMSE = 0,94-0,99 METS). So sánh các mô hình dự báo năng lượng sử dụng dữ liệu từ cả hai chân so với mô hình sử dụng dữ liệu từ một chân duy nhất cho thấy chỉ có một chiếc giày cần phải được trang bị cảm biến. Cảm biến gia tốc được đặt ở mặt sau của chiếc giày cùng với pin và bộ đổi năng lượng. Cảm biến áp suất được đặt ở 5 vị trí khác nhau ở dưới đế giày. Dữ liệu cảm biến được lấy với tần số 25Hz và được chuyển qua máy tính thông qua mạng không dây WISAN (Wireless Intelligent Sensor and Actuator Network).

II. NỘI DUNG

CHƯƠNG 1: TỔNG QUAN VỀ PHÁT HIỆN VẬN ĐỘNG BẤT THƯỜNG

Giới thiệu chương: Chương này trình bày sự cần thiết của việc nhận dạng hoạt động bất thường của con người nói chung và các hoạt động bất thường của con người nói riêng. Các giải pháp công nghệ, các cách tiếp cận đã được sử dụng trong các nghiên cứu của các nhà khoa học trước đây. Từ đó có được cái nhìn tổng quan về các hệ thống phát hiện vận động bất thường của con người.

1.1 Giới thiệu

Nhận dạng các hoạt động của con người một cách tự động đang trở thành hiện thực. Công nghệ dựa trên cảm biến ngày càng dễ tiếp cận. Bằng cách gắn các loại cảm biến khác nhau trên các vị trí và cơ thể con người, hoạt động của con người có thể theo dõi và nhận dạng một cách chính xác. Một ứng dụng quan trọng của việc nhận dạng hoạt động bất thường của con người là giám sát an ninh, xác định các hoạt động khủng bố trong khu vực cần an ninh cao, ở đó mỗi cá nhân vào khu vực an ninh được cấp các trang bị bảo mật có gắn cảm biến. Thông qua một hoặc nhiều cảm biến gắn liền với các trang bị bảo mật cấp cho mỗi người dùng, hoạt động của mỗi cá nhân có thể được theo dõi liên tục nhằm ngăn chặn các hành vi khủng bố. Khi một hoạt động bất thường được phát hiện, hệ thống sẽ phát báo động cho nhân viên an ninh chú ý ngay lập tức. Một số phương pháp để nhận dạng các hoạt động bất thường của con người đã được đề xuất trong quá khứ. Một ứng dụng khác của việc nhận diện các hoạt động bất thường là áp dụng vào hỗ trợ chăm sóc sức khỏe con người, đặc biệt là giúp các bệnh nhân bị rối loạn nhận thức. Nếu một ngôi nhà có thể được thiết kế trang bị một mạng các cảm biến, những người sống trong ngôi nhà sẽ có cơ hội sống tốt hơn, an toàn và độc lập, đặc biệt khi họ bị các bệnh đe dọa tính mạng như bệnh Parkinson hoặc bệnh Alzheimer. Do tính chất quan trọng và thách thức của vấn đề nhận dạng hoạt động bất thường của con người, một số

phương pháp đã được đề xuất để tìm hiểu các hoạt động hàng ngày của con người dựa trên các loại cảm biến; dữ liệu từ các cảm biến thu thập về sẽ được phân tích và xử lý dựa trên mô hình Markov ẩn (HMM) và mạng Bayesian động (DBN). Những mô hình này có thể dự đoán, nhận dạng các loại hoạt động cấp cao của con người dùng dựa trên bộ dữ liệu các hoạt động bất thường đã được thu thập và huấn luyện.

Mặc dù việc phát hiện hoạt động bình thường của người dùng là thú vị và đầy thử thách, vấn đề ngược lại là phát hiện hoạt động bất thường của người dùng từ thiết bị đeo có gắn cảm biến còn nhiều thú vị và thách thức hơn nữa. Vấn đề phát hiện các hoạt động bất thường thú vị vì nó có nhiều ứng dụng từ bảo mật giám sát cho đến chăm sóc sức khỏe cho người cao tuổi. Trong ứng dụng vào việc giám sát an ninh, giả sử rằng nhiệm vụ của chúng ta là theo dõi chuyển động của nhân viên trong một khu vực an ninh cao như một tòa nhà văn phòng chính phủ, các khu nghiên cứu bí mật của quốc gia, hoặc trong các tòa nhà tổ chức hội nghị quốc gia hoặc quốc tế. Một cách tiếp cận là phát hành thẻ được trang bị cảm biến cho mỗi người đi vào khu vực. Sau đó, các thuật toán phát hiện hoạt động bất thường có thể được áp dụng để theo dõi liên tục chuyển động của từng cá nhân để kiểm tra xem hoạt động của người đó có vượt quá tiêu chuẩn. Trong những trường hợp như vậy, nó sẽ có lợi cho phát hiện nếu một hoạt động bất thường bất ngờ xảy ra dựa trên cảm biến và phát ra báo động nếu cần thiết. Phát hiện hoạt động bất thường cũng là rất quan trọng đối với việc ứng dụng vào các lĩnh vực khác. Ví dụ như là trong lĩnh vực y tế chăm sóc sức khỏe cho con người, xem xét một ứng dụng trong chăm sóc sức khỏe, thay vào việc chú ý đến các hoạt động bình thường của bệnh nhân, các bác sĩ hoặc y tá có thể cần quan tâm nhiều hơn đến người già hoặc bệnh nhân khi thấy những dấu hiệu đầu tiên của một căn bệnh nghiêm trọng như là lang thang xung quanh không mục đích, bò lổm ngổm trên sàn nhà hoặc đơn giản rơi xuống.

Vấn đề là thách thức bởi vì, không giống như các hoạt động bình thường, trong việc phát hiện hoạt động bất thường, dữ liệu cực kỳ khan hiếm và ít khi xảy ra trong thực tế so với các hoạt động bình thường của con người. Trong một ứng dụng để

đảm bảo an ninh, ví dụ như là một hệ thống giám sát có thể được huấn luyện để nhận ra chỉ các hoạt động bình thường vì sự sẵn có của dữ liệu hoạt động bình thường, trong khi các hoạt động bất thường là mới đối với hệ thống. Hơn nữa, sau khi tập dữ liệu hoạt động được thu thập và huấn luyện, một người dùng được theo dõi có thể thay đổi các hoạt động mà không có thông báo cho hệ thống biết để học tập. Trong trường hợp này, hệ thống phát hiện hoạt động bất thường có thể cho kết quả nhận dạng sai những hoạt động bất thường và báo động sai. Vì vậy, đây là một nhiệm vụ khó khăn để có thể thiết kế một hệ thống phát hiện hoạt động bất thường có thể giảm thiểu cả tỷ lệ nhận dạng sai. Trong bài luận văn này, các hoạt động bất thường được xem xét như là một hoạt động với các thuộc tính sau:

Các hoạt động hiếm khi xảy ra như ngã, đột quy, bò lồm ngồm.

Các hoạt động không được dự kiến trước như co giật, đang đi vấp ngã, ngồi ngã...

Trước đây, một số cách tiếp cận đã được đề xuất giải quyết vấn đề phát hiện hoạt động bất thường. Những cách tiếp cận này phạm vi từ áp dụng thị giác máy tính, nơi các biến thể của mô hình Markov được thiết kế để phát hiện hành động ngoài định mức bình thường của con người, đến khu vực khai thác thu thập dữ liệu từ các loại cảm biến, nơi các phương pháp dựa trên mô hình học máy được sử dụng để phát hiện các hoạt động bất thường. Tuy nhiên, trong việc sử dụng dữ liệu cảm biến, có khá ít công việc có thể sử dụng thiết bị đeo được có gắn cảm biến để phát hiện các hoạt động bất thường. So với dữ liệu về hình ảnh, dữ liệu thu được từ cảm biến cũng cung cấp một số lợi thế, và thách thức. Về lợi thế của việc sử dụng dữ liệu cảm biến so với việc sử dụng dữ liệu hình ảnh từ các camera, dữ liệu cảm biến cho phép chuyển động của một người được theo dõi liên tục, ít bị ảnh hưởng bởi các yếu tố môi trường. Ngược lại, dữ liệu hình ảnh có thể bị ảnh hưởng lớn từ môi trường như là : khu vực chiếu sáng và sự che phủ và hình ảnh có thể bị nhiễu hoặc khi nhiều đối tượng xuất hiện trong một hình ảnh. Dữ liệu hình ảnh có thể xâm phạm vào quyền riêng tư của mỗi cá nhân (ví dụ: bệnh nhân có thể phản đối việc sử dụng video trong nhà mình, hoặc một số khu vực nhạy cảm không được đặt các thiết bị thu thập hình ảnh). Tuy nhiên, việc sử dụng cảm biến cũng gặp những thách thức

đối với việc triển khai. Ví dụ, cảm biến cần được thiết kế để có thể dễ dàng gắn lên các vật dụng của con người để họ cảm thấy thoải mái và thuận tiện nhất. Một thách thức nữa trong việc sử dụng cảm biến đó là năng lượng để cảm biến có thể hoạt động và kênh truyền tín hiệu từ cảm biến về hệ thống xử lý. Tùy thuộc vào loại khác nhau, cảm biến có thể phát hiện các loại tín hiệu khác nhau, chẳng hạn như các tín hiệu ánh sáng, âm thanh, nhiệt độ, gia tốc và từ trường. Các cảm biến cần có trọng lượng nhẹ để chúng có thể dễ dàng gắn vào cơ thể người. Trong bài luận văn này tôi sử dụng cảm biến WAX để thu thập dữ liệu gia tốc, dùng để phát hiện hoạt động bất thường của con người.


1.2 Các nghiên cứu trước đây về phát hiện hoạt động bất thường

a. Nhận diện hoạt động bất thường bằng cảm biến của Jie Yin [5]

Trong bài báo của mình, Jie Yin [5] đề xuất một cách tiếp cận phát hiện hoạt động bất thường dựa trên dữ liệu thu thập được từ cảm biến. Cách tiếp cận của Jie Yin được lấy cảm hứng từ quan sát rằng, mặc dù các hoạt động bất thường trên thực tế là rất ít, và rất khó để có được một lượng lớn dữ liệu huấn luyện để nhận dạng các hoạt động bất thường, nhưng ngược lại dữ liệu về các hoạt động bình thường thì có thể thu thập được rất nhiều. Điều này cho phép tạo ra các mô hình tốt cho các hoạt động bình thường, từ đó có thể nhận dạng được các hoạt động bình thường. Do đó, Jie Yin đề xuất một phương pháp được chia thành hai giai đoạn để phát hiện hoạt động bất thường, được xây dựng dựa trên dữ liệu từ các hoạt động bình thường.

Trong giai đoạn đầu tiên, Jie Yin xây dựng một one-class SVM (SVM) [15] dựa trên dữ liệu thu thập từ các hoạt động bình thường, mô hình này có thể lọc ra các hoạt động bình thường với độ chính xác cao. Sau đó, các hoạt động đáng ngờ được chuyển sang giai đoạn thứ hai để phát hiện thêm. Trong giai đoạn thứ hai, Jie Yin thực hiện kernel nonlinear regression (KNLR) [3] để thu được các mô hình hoạt động bất thường từ dữ liệu hoạt động bình thường. Điểm mạnh cách tiếp cận của Jie Yin là nó có thể đạt được một tỷ lệ tốt giữa phát hiện hoạt động bất thường và tỷ lệ báo động giả (tức là nhận diện sai hoạt động bất thường) mà không cần thu thập dữ

liệu về các hoạt động bất thường và gắn nhãn chó chúng. Jie Yin thu thập dữ liệu từ các cảm biến có thể đeo gắn liền với người dùng và chứng minh tính hiệu quả của cách tiếp cận bằng cách sử dụng những dữ liệu đã thu thập được trong một môi trường thực tế.

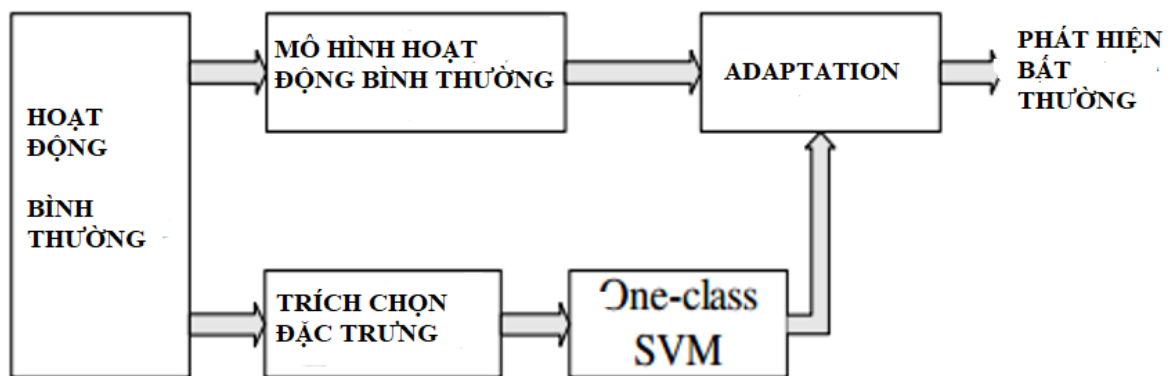


Hình 1-1. Loại cảm biến và vị trí gắn cảm biến [5]

Như trên Hình 1, Tác giả Jie Yin đã sử dụng một thiết bị cảm biến MICA2 gắn trên 3 vị trí là vai, thắt lưng và đầu gối của người dùng. Mỗi thiết bị MICA2 được trang bị 5 loại cảm biến khác nhau bao gồm : cảm biến ánh sáng, cảm biến nhiệt độ, microphone, cảm biến gia tốc 2 chiều và cảm biến từ 2 chiều. Dữ liệu thu thập từ các cảm biến được truyền tới máy tính để xử lý. Jie Yin đã thu thập các dữ liệu về hoạt động của người dùng trong môi trường trong nhà. Và tác giả cũng thu thập một vài dữ liệu về hoạt động bất thường như là “bò lỏm ngổm trên sàn nhà”, “ngã trên

sản nhà”,... Mỗi một bộ dữ liệu là một vector 7 chiều thu được từ các loại cảm biến gắn trên thiết bị.

Sau khi thu thập được dữ liệu từ những người dùng hỗ trợ, Jie Yin có một bộ dữ liệu để thực hiện huấn luyện mô hình học máy, từ đó xây dựng hệ thống nhận dạng hoạt động bất thường theo như mô hình :



Hình 1-2. Mô hình nhận dạng hoạt động bất thường của Jie Yin [5]

Như trên hình mô tả luồng xử lý dữ liệu của Jie Yin để nhận dạng các hoạt động bất thường. Sau khi thu thập được bộ dữ liệu các hoạt động bình thường $\{Y_1, Y_2, \dots, Y_n\}$ thuật toán của tác giả chia làm 2 pha. Trong pha đầu tiên, tất cả dữ liệu về hoạt động bình thường được tiền xử lý và trích chọn các đặc trưng. Sau đó thông qua thuật toán One-Class SVM [15] để huấn luyện, dùng để loại bỏ các hoạt động có xác suất cao là hoạt động bình thường. Với những dữ liệu nghi ngờ là hoạt động bất thường sẽ được đưa qua pha thứ hai để nhận dạng xem nó là hoạt động bình thường hay bất thường.

Giai đoạn xây dựng mô hình phân loại One-Class SVM [15]

Mục tiêu của tác giả là tự động phát hiện các hoạt động bất thường của con người khi mà tác giả chỉ có một bộ dữ liệu các hoạt động bình thường để huấn luyện. Do đó, cách tiếp cận trực tiếp là tìm hiểu ranh giới quyết định xung quanh dữ liệu bình thường và sau đó sử dụng ranh giới đó để phân loại các hoạt động như

bình thường hoặc bất thường. Để làm điều này, tác giả sử dụng thuật toán One-Class SVM để phân loại.


Để huấn luyện một One-Class SVM, trước tiên tác giả đã tiền xử lý dữ liệu để chuyển đổi các dữ liệu huấn luyện có độ dài biến đổi thành một tập hợp các vector đặc trưng độ dài cố định. Giả sử rằng, bộ dữ liệu huấn luyện có M loại hoạt động bình thường khác nhau (đi bộ, chạy, nhảy,...). Với mỗi một loại hoạt động, tác giả sử dụng thuật toán Baum-Welch để huấn luyện ra M mô hình Markov ẩn (HMM), mỗi mô hình học máy tương ứng là λ_i với $1 \leq i \leq M$. Giả sử trong tập dữ liệu huấn luyện có N bộ dữ liệu cho các hoạt động, với mỗi bộ dữ liệu tác giả tính toán giá trị log-likelihood từ các mô hình học máy λ_i . Công thức tính:

$$L(Y_i; \lambda_j) = \log P(Y_i | \lambda_j), \quad 1 \leq i \leq N, \quad 1 \leq j \leq M. \quad (1.1)$$

Bằng cách tính toán như vậy, với mỗi bộ dữ liệu dùng để huấn luyện, Jie Yin đã thu được vector đặc trưng $x_i = (L(Y_i; \lambda_1), \dots, L(Y_i; \lambda_M))$.

Sau khi chuyển đổi N bộ dữ liệu trong tập dữ liệu huấn luyện thành một tập các vector đặc trưng x_1, x_2, \dots, x_n . Từ tập các vector đặc trưng thu được Jie Yin sử dụng để huấn luyện bằng thuật toán One-Class SVM để huấn luyện ra mô hình dùng để phân loại các hoạt động bình thường. Với những bộ dữ liệu sau khi qua One-Class SVM phân loại với xác suất cao thì có thể coi đó là hoạt động bình thường. Chỉ những hoạt động có xác suất thấp, được coi là hoạt động đáng ngờ sẽ được chuyển qua bước tiếp theo để nhận dạng đó có phải hoạt động bất thường. Như vậy có thể coi One-Class SVM giống như một bộ lọc các dữ liệu bình thường lần 1.

Giai đoạn xây dựng mô hình các hoạt động bất thường:



Hình 1-3. Xây dựng mô hình hoạt động bất thường [5]

Jie Yin đã tạo ra mô hình nhận dạng các hoạt động bất thường từ mô hình nhận dạng hoạt động bình thường. Như trên hình 3.a, bắt đầu với một mô hình cho hoạt động bình thường, tác giả tính toán giá trị likelihood cho mỗi bộ dữ liệu thu thập được. Sau đó so sánh với một giá trị ngưỡng θ , nếu giá trị likelihood nhỏ hơn giá trị ngưỡng θ thì Jie Yin xác định đó là một bộ dữ liệu đáng ngờ. Các bộ dữ liệu đáng ngờ có thể coi là đại diện cho một loại hành động bất thường cụ thể và do đó có thể dùng để huấn luyện tạo ra mô hình cho các hoạt động bất thường. Tuy nhiên chỉ với các bộ dữ liệu đáng ngờ là chưa đủ để tạo ra một mô hình hoạt động bất thường tốt. Vì vậy tác giả đã sử dụng thêm thuật toán kernel nonlinear regression (KNLR) [4] để phân tích và điều chỉnh từ mô hình hoạt động bình thường thành mô hình hoạt động bất thường sử dụng những bộ dữ liệu đáng ngờ như hình 3.b. Sau đó khi một bộ dữ liệu test đến, tác giả tính toán giá trị lớn nhất likelihood cho bộ dữ liệu này từ những mô hình hiện có. Nếu giá trị lớn nhất likelihood này được tạo ra từ mô hình hoạt động bình thường thì tác giả dự đoán đây là hoạt động bình thường. Ngược lại tác giả xác định đó là hoạt động bất thường, trong trường hợp này tác giả xem xét để tạo ra một mô hình hoạt động bất thường mới. Nếu giá trị lớn nhất likelihood lớn hơn giá trị ngưỡng θ , tác giả coi đây là bộ dữ liệu thuộc về một mô hình hoạt động bất thường hiện có, ngược lại tác giả cân nhắc việc tạo ra mô hình hoạt động bất thường mới.

Phương pháp đánh giá và kết quả thực nghiệm:

Kết quả của thuật toán nhận dạng các hoạt động bất thường của tác giả Jie Yin được đánh giá qua hai độ đo: tỷ lệ phát hiện (*detection rate*) và tỷ lệ cảnh báo sai (*false alarm rate*). Giá trị tỷ lệ phát hiện được xác định tính toán bằng tỷ lệ phát hiện các hoạt động bất thường trên tổng số các hoạt động bất thường. Giá trị tỷ lệ cảnh báo sai được xác định bằng tỷ lệ số lượng các hoạt động bình thường bị xác định sai thành hoạt động bất thường trên tổng số các hoạt động bình thường.

$$\text{Detection Rate} = \text{TN} / (\text{TN} + \text{FN}) \quad (1.2)$$


$$\text{False Alarm Rate} = \text{FP} / (\text{FP} + \text{TP}) \quad (1.3)$$

Thuật toán nhận dạng hoạt động bất thường được đánh giá là tốt nếu có tỷ lệ phát hiện cao và tỷ lệ cảnh báo sai là thấp.

		Actual Label	
		Normal	Abnormal
Predicted Label	Normal	True Positive (TP)	False Negative (FN)
	Abnormal	False Positive (FP)	True Negative (TN)

Bảng 1-1 - Bảng ma trận lỗi.

Tác giả Jie Yin đã sử dụng phương pháp đường cong ROC để đánh giá hiệu quả của thuật toán.



Hình 1- 4 - Kết quả thực nghiệm Jie Yin

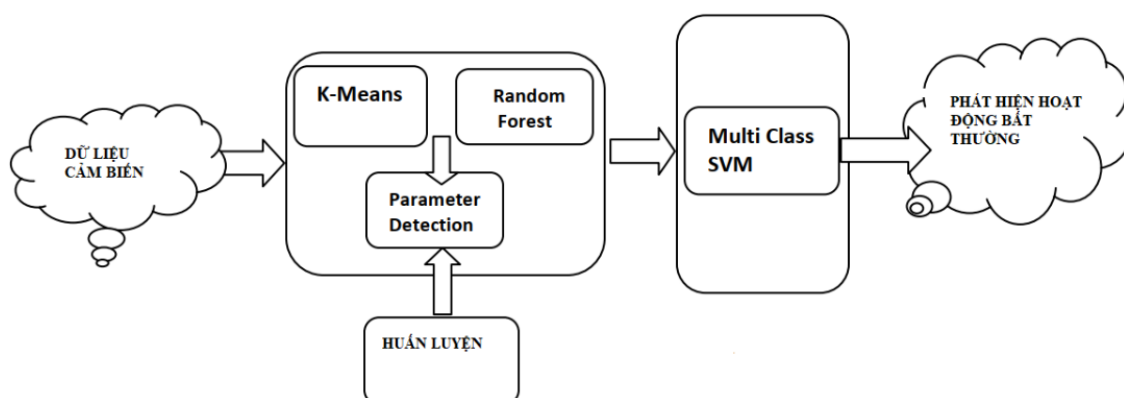
Trên hình là ví dụ về đường cong ROC thể hiện kết quả thực nghiệm của 3 thuật toán phát hiện hoạt động bất thường của tác giả Jie Yin. Từ kết quả cho thấy thuật toán phát hiện hoạt động bất thường SVM+KNLR cho kết quả tốt nhất.

b. Phát hiện hoạt động bất thường sử dụng SVM của Ms. Apurva Landge [12]

Tác giả đã giới thiệu một cách tiếp cận mới để tăng cường tính chính xác của việc phát hiện hoạt động bất thường của con người. Tác giả đã phân loại các hoạt động của con người bằng cách sử dụng các thuật toán K-Means, Random Forest và SVM nhiều lớp [13]. SVM giúp phân loại dữ liệu vì nó được sử dụng để phân loại hình ảnh và dữ liệu của nó. K-mean là một trong những thuật toán học tập không giám sát đơn giản nhất để giải quyết vấn đề phân cụm nổi tiếng. Nó tạo thành các cụm hoạt động tương tự. Nó tính khoảng cách giữa mỗi thuộc tính của dữ liệu và hình thành cụm các hoạt động khác nhau. Thuật toán Random Forest là thuật toán để sử dụng cho các nhiệm vụ phân loại phức tạp. Vì vậy tác giả đã sử dụng K-

Means và Random Forest cùng nhau để phân loại và phát hiện các hoạt động bất thường một cách hiệu quả.

Tác giả đề xuất phương pháp phát hiện hoạt động bất thường của con người dựa trên các hoạt động liên tiếp của con người, được thiết kế dựa trên các thuật toán SVM, K-Means và Random Forest. Sơ đồ kiến trúc mô hình phát hiện hoạt động bất thường của tác giả:



Hình 1-5 : Mô hình phát hiện hoạt động bất thường của Apurva Landge [12]

Dữ liệu từ các cảm biến sẽ được thu thập, sau đó liên tục được truyền đến ứng dụng có mặt tại bệnh viện hoặc bất kỳ nơi nào để giúp đỡ nếu có hoạt động bất thường diễn ra. Dữ liệu thu được theo dõi liên tục và so sánh với các thông số, thuộc tính và mẫu khác nhau. Dữ liệu được thu thập bằng cảm biến, nó được lọc bằng bộ lọc High Pass và Low Pass. Dữ liệu sau khi được lọc sẽ được sử dụng để trích chọn các đặc trưng để huấn luyện mô hình học máy.

Các đặc trưng được tác giả sử dụng là : độ lệch chuẩn dùng để đo mức độ phân tán của dữ liệu. RMS (Root mean square) hay còn gọi là giá trị hiệu dụng là căn bậc hai của trung bình bình phương của các giá trị dữ liệu cảm biến được đo tức thời trong một khoảng thời gian nhất định [14]. Tỷ lệ-pNN50, số lượng chênh lệch giữa các khoảng thời gian NN liên tiếp lớn hơn 50ms (NN50) được tính toán [15]. Nó được sử dụng cho tỷ lệ xuất phát bằng cách chia NN50 cho tổng số của các khoảng

NN (pNN50) [12]. Tất cả các giá trị đặc trưng được tính toán và sử dụng để đào tạo mô hình học máy để phát hiện các hoạt động bất thường.

SVM là mô hình học máy có giám sát, để phân tích dữ liệu và nhận dạng các mẫu, được sử dụng cho phân loại và phân tích hồi quy. SVM phân loại hoạt động thành các nhãn đơn, vì vậy để phân loại được nhiều hoạt động phải cần nhiều thời gian để thu thập dữ liệu nhiều hoạt động, gán nhãn, mất nhiều thời gian để tính toán xử lý.

K-mean là một trong những thuật toán học tập không giám sát đơn giản nhất giải quyết tốt vấn đề phân cụm. Thuật toán tạo ra các cụm hoạt động tương tự. Nó được sử dụng để gom nhóm phân cụm các nhóm hoạt động tương tự vào với nhau, từ đó nhanh chóng có thể tìm ra các hoạt động bất thường. Thuật toán dễ dàng để phân loại một tập dữ liệu nhất định thông qua một số cụm nhất định.

Random Forest là một phương pháp xây dựng một số cây quyết định từ tập dữ liệu từ các cảm biến đã được gán nhãn cho các hoạt động. Thuật toán Random Forest là một thuật toán tốt để sử dụng cho nhiệm vụ phân loại.

Tác giả sử dụng các thuật toán trên để phân loại các hoạt động của con người, và tìm ra được hoạt động bất thường. Hoạt động bất thường có thể được phát hiện bằng cách phân loại các hoạt động được xác định. Nếu bất kỳ hành động xảy ra ngoài phạm vi phân loại của các thuật toán, hành động được đánh dấu là bất thường.

1.3 Phạm vi và các giả định

Luân văn nghiên cứu nhận dạng các hoạt động bất thường của con người giới hạn trong 17 hoạt động trong danh sách. Với giả định các hoạt động bất thường là các hoạt động ngã của con người, còn lại là các hoạt động bình thường.

Phạm vi và giả định các hoạt động bất thường :

+ Ngã về phía trước

+ Ngã về phía sau

- + Ngã về bên trái
- + Ngã về bên phải
- + Ngồi trên ghế và ngã về bên trái
- + Ngồi trên ghế và ngã về bên phải

Người sử dụng phải được đeo cảm biến gia tốc để gửi dữ liệu gia tốc về ứng dụng.

Các hoạt động diễn ra đủ ngắn và trong phạm vi một phòng giới hạn, vì khoảng các truyền dữ liệu từ cảm biến về ứng dụng có giới hạn về khoảng cách.


CHƯƠNG 2: PHÁT HIỆN HOẠT ĐỘNG BẤT THƯỜNG CỦA CON NGƯỜI

Chương 2 bắt đầu bằng thiết kế và chế tạo vòng đeo tay thông minh, dây thắt lưng thông minh có gắn cảm biến gia tốc; phương pháp phân tích và xử lý dữ liệu cảm biến; và phương pháp phát hiện hoạt động bất thường.


2.1. Thiết kế vòng đeo tay thông minh, dây thắt lưng thông minh

2.1.1. Cảm biến gia tốc WAX3

WAX3 là cảm biến gia tốc theo ba trục x,y,z có kích thước rất nhỏ. Cảm biến này có thời gian thu thập và xử lý dữ liệu ngắn phù hợp với việc thu thập và xử lý dữ liệu thời gian thực. Một số hình ảnh về cảm biến WAX3 :



Hình 2-1 Kích thước cảm biến WAX3



Hình 2-2 hình dạng cảm biến WAX3

Một số thông số của cảm biến WAX3 :

- +/- 16g 3-axis accelerometer.
- 4 mg resolution.
- 25m range indoors.
- USB 2.0 enabled.
- Rechargeable Li-Polymer battery.
- Fully re-configurable functionality.
- Expansion port for other sensors.
- Accelerometer rate up to 2 ks.sec-1.

Dữ liệu mà WAX3 gửi về theo từng gói (Packet). Để nhận biết kết thúc mỗi gói là ký tự END (END = 0xC0). Vì đặc điểm này mà khi thực hiện chương trình, sẽ cho một tiến trình chuyên bắt dữ liệu từ WAX3 gửi về, khi gặp ký tự END thì có nghĩa là đã đủ một Packet, chương trình sẽ xử lý Packet đó.

Cấu trúc của một Packet có dạng như sau :

Bytes Bắt đầu	Độ dài	Tên	Mô tả
0	1 bytes	reportType	0x12 (User)
1	1 bytes	reportId	0x78 ASCII
2	2 bytes	deviceId	Mã thiết bị
4	1 bytes	Status	0 pin yếu
5	2 bytes	sample	Dữ liệu cảm biến
7	1 bytes	format	Định dạng dữ liệu
8	2 bytes	sequenceId	Số thứ tự
10	1 bytes	Outstanding	Đặc điểm thiết bị
11`	1 bytes	SampleCount	Số lượng sample
12		sampleData	

Bảng 2-1 : Cấu trúc của một Packet

8 bit của bytes Format có dạng : rreeffff.

Nếu ee = 2 thì 1 sampleData có 6 bytes dữ liệu tương ứng :

Bytes bắt đầu	Độ dài	Name
0	2 bytes	X Axis
2	2 bytes	Y Axis
4	2 bytes	Z Axis

Bảng 2-2 : Cấu trúc một SampleData

Nếu ee = 0 thì 1 sampleData có 4 bytes dữ liệu, với cấu trúc như sau :

eezzzzzz zzzzyyyy yyyyyyxx xxxxxxxx

Thiết bị WAX3 được cấu hình đầy đủ bằng cách sử dụng phần mềm OM (tỷ lệ mẫu, độ nhạy, tốc độ truyền tải, phạm vi hoạt động). Thiết bị có thể được đưa vào chế độ ngủ để vận chuyển an toàn. Trong chế độ bình thường các thiết bị được cấu hình để bắt đầu truyền tải bất cứ khi nào cảm biến gia tốc phát hiện chuyển động.

2.1.2.Thiết kế vòng đeo tay thông minh

Cảm biến WAX3 được lắp vào mặt trước của vòng đeo tay như hình :



Hình 2-3: Vòng đeo tay thông minh

Vòng đeo tay được người sử dụng đeo vào tay bên phải và thực hiện các hoạt động để thu thập dữ liệu cảm biến từ các hoạt động khác nhau trong phòng.

2.1.2.Thiết kế dây thắt lưng thông minh

Cảm biến WAX3 được gắn vào dây thắt lưng của người sử dụng và ở vị trí eo bên phải của người đeo.

2.2. Phân tích và xử lý dữ liệu cảm biến

2.2.1. *Tiền xử lý dữ liệu*

Như phần mô tả về cảm biến WAX3 ở trên thì dữ liệu cảm biến gửi về dưới dạng các Packet, trong mỗi Packet thì có nhiều Sample, mỗi Sample chứa một bộ ba giá trị gia tốc theo 3 trục là x , y , z . Chính vì vậy đầu tiên ta cần 2 lớp dùng để mô tả và đóng gói dữ liệu này lại là lớp WaxPacket và WaxSample

Sau khi đã có được 2 lớp mô tả dữ liệu, chương trình sẽ tiến hành thu nhận dữ liệu từ cổng COM được kết nối với thiết bị nhận. Lớp ListenFromPort sẽ đảm nhiệm nhiệm vụ này bằng cách tạo ra một tiến trình liên tục đọc dữ liệu từng bytes một từ cổng COM lưu trữ vào một mảng cho đến khi gặp bytes kết thúc Packet. Khi đó mảng chứa dữ liệu các bytes nhận về chính là dữ liệu của một Packet.

Sau khi có được một mảng các bytes là một Packet nhận về, ta tiến hành xử lý đoạn bytes đó để được một Packet như trong mô tả của lớp. Lớp đảm nhận trách nhiệm này là lớp WaxPacketConverter. Dữ liệu đầu vào là mảng các bytes của Packet và dữ liệu đầu ra là dữ liệu được mô tả như trong lớp WaxPacket. Để thực hiện được điều này, ta cần dựa vào cấu trúc định dạng của một Packet như trong phần mô tả về cảm biến WAX3 ở trên.

Sau khi xử lý được dữ liệu từ cảm biến gửi về dưới dạng các bytes liên tiếp nhau, ta đã thu được dữ liệu tương minh được đóng gói trong lớp WaxPacket. Từ đây ta sẽ sử dụng dữ liệu là các WaxPacket này để làm các công việc tiếp theo như ghi dữ liệu xuống file, phân tích dữ liệu, tính toán các đặc trưng...

2.2.2. *Phân đoạn và trích các đặc trưng*

Sau khi có dữ liệu nhận về, việc tiếp theo hết sức quan trọng, quyết định đến khả năng nhận dạng được các hoạt động bất thường của con người. Đó chính là việc trích chọn ra các đặc trưng phù hợp. Sau khi tham khảo nhiều tài liệu liên quan tôi thấy có nhiều đặc trưng có thể chọn, tuy nhiên để phù hợp với đề tài của mình là

"Nhận dạng hoạt động bất thường của con người", tôi quyết định sử dụng 4 đặc trưng sau:

- Trung bình cộng (Mean Value)
- Độ lệch chuẩn (Standard Deviation)
- Entropy thông tin
- Sự tương quan (Corelation)

a. Trung bình cộng (Mean Value):

Mean Value hay còn gọi là trung bình cộng là từ mà thường dùng để chỉ trung bình theo đúng nghĩa đen thông dụng. Giá trị trung bình cộng được tính bằng cách cộng tất cả các phần tử trong tập hợp đang xét lại rồi chia đều cho số lượng phần tử. Giá trị trung bình cộng được tính theo công thức :

$$b(t) = \frac{1}{N} \sum_{t=1}^n a(t) \quad (2.1)$$

Trong đó :

- N là số lượng phần tử trong mảng a
- a(t) là giá trị phần tử thứ t trong mảng a

Đại lượng này rất hữu ích cho việc phân biệt các hoạt động có cường độ vận động cao với các hoạt động có cường độ vận động thấp.

b. Độ lệch chuẩn (Standard Deviation):

Độ lệch chuẩn (Standard Deviation) là một đại lượng sử dụng khá phổ biến trong thống kê. Độ lệch chuẩn là một đại lượng thống kê mô tả dùng để đo mức độ phân tán của một tập dữ liệu đã được lập thành bảng tần số. Có thể tính ra độ lệch chuẩn bằng cách lấy căn bậc hai của phương sai.

Khi hai tập dữ liệu có cùng giá trị trung bình cộng, tập nào có độ lệch chuẩn lớn hơn là tập có dữ liệu biến thiên nhiều hơn. Trong trường hợp hai tập dữ liệu có giá trị trung bình cộng không bằng nhau, thì việc so sánh độ lệch chuẩn của chúng không có ý nghĩa. Độ lệch chuẩn còn được sử dụng khi tính sai số chuẩn. Khi lấy độ lệch chuẩn chia cho căn bậc hai của số lượng quan sát trong tập dữ liệu, sẽ có giá trị của sai số chuẩn.

Phương pháp tính độ lệch chuẩn từ một dãy n giá trị cho trước x_1, x_2, \dots, x_n :

- Tìm mean của dãy số x_1, x_2, \dots, x_n .
- Với mỗi x trong dãy số đã cho, tính độ lệch của nó so với mean bằng phép tính $(x - \text{mean})$.
- Tính bình phương của các giá trị thu được ở bước 2.
- Tính mean của các bình phương độ lệch tìm được ở bước 3. Giá trị này được biết đến như là phương sai.
- Tính căn bậc hai của phương sai ta được giá trị độ lệch chuẩn.

Công thức tính độ lệch chuẩn

$$Std = \sqrt{\frac{\sum_1^N (x(i) - \text{mean}(x))^2}{N}} \quad (2.2)$$

Đại lượng này giúp chúng ta phân biệt được các hoạt động có giá trị mean bằng nhau, tập nào có độ lệch chuẩn lớn hơn thì tập đó có dữ liệu biến thiên nhiều hơn. Chúng ta tập đó giá trị gia tốc biến thiên nhiều hơn và đa dạng về giá trị hơn..

c. Entropy Thông tin:

Entropy thông tin là một khái niệm mở rộng của entropy trong nhiệt động lực học và cơ học thống kê sang cho lý thuyết thông tin.

Entropy thông tin mô tả mức độ hỗn loạn trong một tín hiệu lấy từ một sự kiện ngẫu nhiên. Nói cách khác, entropy cũng chỉ ra có bao nhiêu thông tin trong tín hiệu, với thông tin là các phần không hỗn loạn ngẫu nhiên của tín hiệu.

Ví dụ, nhìn vào một dòng chữ tiếng việt, được mã hóa bởi các chữ cái, khoảng cách, và dấu câu, tổng quát là các ký tự. Dòng chữ có ý nghĩa sẽ không hiện ra một cách hoàn toàn hỗn loạn ngẫu nhiên. Ví dụ như tần số xuất hiện chữ cái x sẽ không giống với tần số xuất hiện chữ cái phổ biến hơn là t . Đồng thời, nếu dòng chữ vẫn đang được viết hay đang được truyền tải, khó có thể đoán trước được ký tự tiếp theo sẽ là gì, do đó nó có mức độ ngẫu nhiên nhất định. Entropy thông tin là một thang đo mức độ ngẫu nhiên này.

Claude E. Shannon đã xây dựng định nghĩa về entropy để thỏa mãn các giả định sau :

- Entropy phải tỷ lệ thuận liên tục với các xác suất xuất hiện của các phần tử ngẫu nhiên trong tín hiệu.
- Thay đổi nhỏ trong xác suất phải dẫn đến thay đổi nhỏ trong entropy.
- Nếu các phần tử ngẫu nhiên đều có xác suất xuất hiện bằng nhau, việc tăng số lượng phần tử ngẫu nhiên phải làm tăng entropy.
- Có thể tạo các chuỗi tín hiệu theo nhiều bước, và entropy tổng cộng phải bằng tổng có trọng số của entropy của từng bước.

Công thức tính entropy :

$$\varepsilon = -k \sum_{i=1}^N p(i) \log p(i) \quad (2.3)$$

Trong đó :

- K là hằng số, chỉ phụ thuộc vào đơn vị đo
- N là tổng số các giá trị có thể nhận của tín hiệu.
- i là giá trị rời rạc thứ i.
- p(i) là xác suất xuất hiện của giá trị i.

d. Độ tương quan (Correlation):

Trong đề tài này, dữ liệu nhận về là bộ ba giá trị là gia tốc theo ba trục x, y, z. Chính vì vậy chúng ta cần biết độ tương quan giữa các biến x, y, z để thuận lợi trong quá trình nhận dạng hoạt động của con người.

Trong đề tài, sử dụng hệ số tương quan Pearson. Hệ số tương quan Pearson (Pearson correlation coefficient, kí hiệu r) đo lường mức độ tương quan tuyến tính giữa hai biến. Về nguyên tắc, tương quan Pearson sẽ tìm ra một đường thẳng phù hợp nhất với mối quan hệ tuyến tính của 2 biến.

Hệ số tương quan Pearson (r) sẽ nhận giá trị từ -1 đến +1. $r > 0$ cho biết một sự tương quan thuận giữa hai biến, nghĩa là nếu giá trị của biến này tăng thì sẽ làm tăng giá trị của biến kia và ngược lại. $r < 0$ cho biết một sự tương quan nghịch giữa hai biến, nghĩa là nếu giá trị của biến này tăng thì sẽ làm giảm giá trị của biến kia và ngược lại. Giá trị tuyệt đối của r càng cao thì mức độ tương quan giữa hai biến càng

lớn hoặc dữ liệu càng phù với quan hệ tuyến tính giữa hai biến. Giá trị r bằng $+1$ hoặc bằng -1 cho thấy dữ liệu hoàn toàn phù hợp với mô hình tuyến tính.

Công thức để tính độ tương quan giữa hai biến x, y :

$$r_{12} = \frac{1}{N} \sum_{i=1}^N \left(\frac{a1(i) - a1}{s1} \right) \left(\frac{a2(i) - a2}{s2} \right) \quad (2.4)$$

Trong đó

- $a1(i), a2(i)$ là các giá trị gia tốc thu được trên hai trục x, y .
- $a1, a2$ là giá trị mean.
- N là số tín hiệu đọc được.
- $s1, s2$ là giá trị độ lệch chuẩn.

Đại lượng này giúp hệ thống phân biệt các hoạt động có cường độ và hướng khác nhau.


2.3. Phát hiện hoạt động bất thường

2.3.1 Huấn luyện mô hình học máy


Thuật toán được sử dụng để huấn luyện mô hình học máy cho đề tài là One Class SVM. One Class SVM có thể được coi như là một thuật toán SVM 2 lớp thông thường, trong đó tất cả dữ liệu được sử dụng để huấn luyện mô hình học máy đều nằm trong một lớp. Vì vậy thuật toán bản chất tìm một siêu phẳng (hyperplane) chứa hầu hết các dữ liệu được huấn luyện.

$$f(x) = \langle W, X \rangle + b \quad (2.5)$$

Trong đó W : các vector dữ liệu bình thường được mang đi huấn luyện.



Hình 2-4 : Ví dụ hình ảnh phát hiện điểm bất thường bằng One Class SVM
Dữ liệu cảm biến gia tốc WAX3 thu thập được từ các hoạt động bình thường được mang đi huấn luyện mô hình học máy :



Hình 2-5 : Mô hình huấn luyện mô hình học máy

Giải pháp thứ nhất : chia dữ liệu ra thành các cửa sổ :

Dữ liệu thu được từ cảm biến WAX3 lúc đầu là các vector có dạng $(x1, y1, z1, x2, y2, z2)$. Dữ liệu được chia thành các cửa sổ, mỗi cửa sổ 50 mẫu tương ứng với 50 bộ vector. Mỗi bộ vector sẽ được tính toán các giá trị đặc trưng : Mean Value, Standard Deviation, Entropy Thông tin, Correlation. Các bộ giá trị đặc trưng của các hoạt động gán nhãn là hoạt động bình thường được tính toán được làm bộ dữ liệu để huấn luyện cho thuật toán One Class SVM. Đầu ra của thuật toán thu được Model cho các hoạt động bình thường.

Giả sử một cửa sổ gồm 50 bộ vector như sau :

$$[[x_{11}, y_{11}, z_{11}, x_{12}, y_{12}, z_{12}]$$

$$[x_{21}, y_{21}, z_{21}, x_{22}, y_{22}, z_{22}]$$

$$[x_{31}, y_{31}, z_{31}, x_{32}, y_{32}, z_{32}]$$

....

$$[x_{N1}, y_{N1}, z_{N1}, x_{N2}, y_{N2}, z_{N2}]]$$

Trong đó $N = 50$.

Tính giá trị trung bình cộng của từng $x_1, y_1, z_1, x_2, y_2, z_2$

$$TbX1 = \frac{1}{N} \sum_{t=1}^N x(t)1 \quad (2.6)$$

$$TbY1 = \frac{1}{N} \sum_{t=1}^N y(t)1 \quad (2.7)$$

$$TbZ1 = \frac{1}{N} \sum_{t=1}^N z(t)1 \quad (2.8)$$

$$TbX2 = \frac{1}{N} \sum_{t=1}^N x(t)2 \quad (2.9)$$

$$TbY2 = \frac{1}{N} \sum_{t=1}^N y(t)2 \quad (2.10)$$

$$TbZ2 = \frac{1}{N} \sum_{t=1}^N z(t)2 \quad (2.11)$$

Tính giá trị độ lệch chuẩn của từng $x_1, y_1, z_1, x_2, y_2, z_2$

$$StdX1 = \sqrt{\frac{\sum_1^N (x(t)1 - TbX1)^2}{N}} \quad (2.12)$$

$$StdY1 = \sqrt{\frac{\sum_1^N (y(t)1 - TbY1)^2}{N}} \quad (2.13)$$

$$StdZ1 = \sqrt{\frac{\sum_1^N (z(t)1 - TbZ1)^2}{N}} \quad (2.14)$$

$$StdX2 = \sqrt{\frac{\sum_1^N (x(t)2 - TbX2)^2}{N}} \quad (2.15)$$

$$StdY2 = \sqrt{\frac{1 \sum_1^N (y(t)2 - TbY2)^2}{N}} \quad (2.16)$$

$$StdZ2 = \sqrt{\frac{1 \sum_1^N (z(t)2 - TbZ2)^2}{N}} \quad (2.17)$$

Tính giá trị Entropy của từng x1, y1, z1, x2, y2, z2

$$EntX1 = -k \sum_{i=1}^N p(x1(i)) \log p(i) \quad (2.18)$$

$$EntY1 = -k \sum_{i=1}^N p(y1(i)) \log p(i) \quad (2.19)$$

$$EntZ1 = -k \sum_{i=1}^N p(z1(i)) \log p(i) \quad (2.20)$$

$$EntX2 = -k \sum_{i=1}^N p(x2(i)) \log p(i) \quad (2.21)$$

$$EntY2 = -k \sum_{i=1}^N p(y2(i)) \log p(i) \quad (2.22)$$

$$EntZ2 = -k \sum_{i=1}^N p(z2(i)) \log p(i) \quad (2.23)$$

Tính các giá trị độ tương quan của các cặp (x1, y1) , (y1, z1) , (z1, x1) , (x2, y2) , (y2, z2) , (z2, x2)

$$R_{x1y1} = \frac{1}{N} \sum_{i=1}^N \left(\frac{x1(i) - TbX1}{StdX1} \right) \left(\frac{y1(i) - TbY1}{StdY1} \right) \quad (2.24)$$

$$R_{y1z1} = \frac{1}{N} \sum_{i=1}^N \left(\frac{y1(i) - TbY1}{StdY1} \right) \left(\frac{z1(i) - TbZ1}{StdZ1} \right) \quad (2.25)$$

$$R_{z1x1} = \frac{1}{N} \sum_{i=1}^N \left(\frac{z1(i) - TbZ1}{StdZ1} \right) \left(\frac{x1(i) - TbX1}{StdX1} \right) \quad (2.26)$$

$$R_{x2y2} = \frac{1}{N} \sum_{i=1}^N \left(\frac{x2(i) - TbX2}{StdX2} \right) \left(\frac{y2(i) - TbY2}{StdY2} \right) \quad (2.27)$$

$$R_{y2z2} = \frac{1}{N} \sum_{i=1}^N \left(\frac{y2(i) - TbY2}{StdY2} \right) \left(\frac{z2(i) - TbZ2}{StdZ2} \right) \quad (2.28)$$

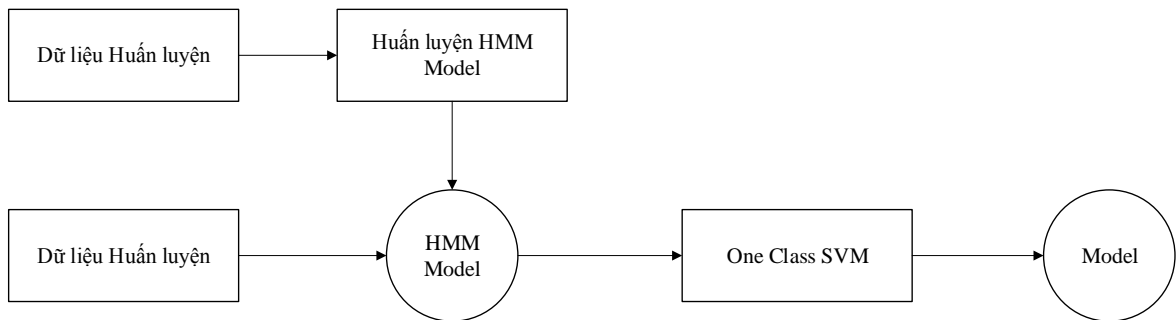
$$R_{z2x2} = \frac{1}{N} \sum_{i=1}^N \left(\frac{z2(i) - TbZ2}{StdZ2} \right) \left(\frac{x2(i) - TbX2}{StdX2} \right) \quad (2.29)$$

Sau khi tính toán các giá trị đặc trưng của bộ 50 vector dữ liệu, ta có được một vector đặc trưng 24 chiều cho bộ dữ liệu đó :

$$(TbX1, TbY1, TbZ1, \dots, R_{x2y2}, R_{y2z2}, R_{z2x2})$$

Tập dữ liệu các hoạt động bình thường được chia thành M khung, mỗi khung sẽ tính toán ra được 1 vector đặc trưng dùng để huấn luyện cho mô hình học máy One Class SVM.


Giải pháp thứ hai : Sử dụng Hidden Markov Models để trích chọn đặc trưng




Hình 2-6 : Mô hình huấn luyện mô hình học máy

Toàn bộ dữ liệu của các hoạt động bình thường được gán nhãn. Với mỗi bộ dữ liệu của một hoạt động bình thường được sử dụng làm dữ liệu huấn luyện cho một model HMM. Giả sử toàn bộ dữ liệu hoạt động bình thường thu thập được có M các hoạt động bình thường. Sau khi huấn luyện ta thu được M model HMM cho các hoạt động bình thường.

Một số mô hình HMM của các hoạt động bình thường như sau :



Hình 2- 7 : Mô hình HMM cho hoạt động đi bộ các hướng.



Hình 2-8 : Mô hình HMM cho hoạt động Chạy chậm.

Sau khi có được M mô hình HMM cho M loại hoạt động bình thường. Với mỗi một bộ dữ liệu từ cảm biến WAX3 ($x_1, y_1, z_1, x_2, y_2, z_2$), tính toán giá trị log-

likelihood từ các mô hình HMM của các hoạt động bình thường ở trên. Công thức tính:

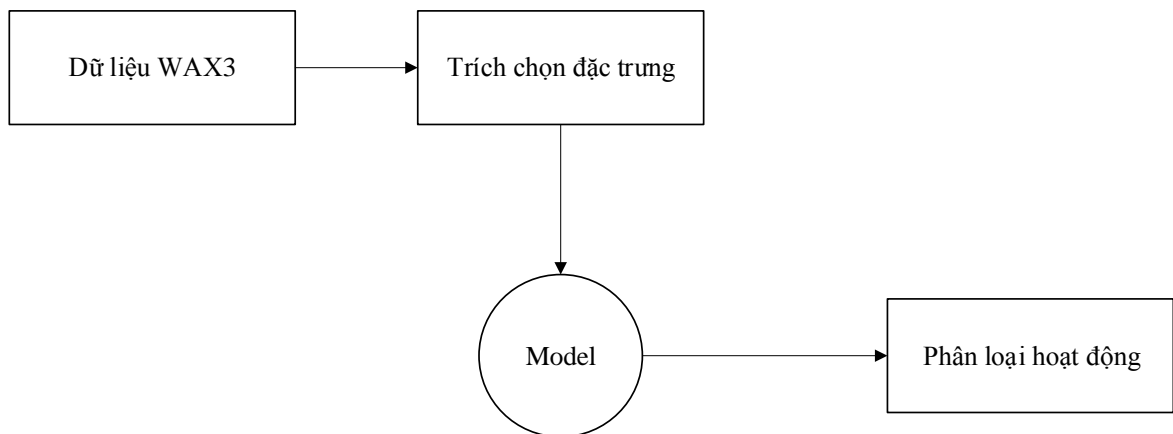
$$L(Y_i; \lambda_j) = \log P(Y_i | \lambda_j), 1 \leq i \leq N, 1 \leq j \leq M. \quad (2.30)$$

Trong đó : M là số mô hình HMM của hoạt động bình thường

N : là số lượng các bộ số dữ liệu (x1, y1, z1, x2, y2, z2)

Bằng cách tính toán như vậy, với mỗi bộ dữ liệu dùng để huấn luyện, thu được vector đặc trưng $x_i = (L(Y_i; \lambda_1), \dots, L(Y_i; \lambda_M))$. Từ các vector đặc trưng này, ta sử dụng thuật toán One Class SVM để huấn luyện mô hình phát hiện các hoạt động bất thường.

2.3.2 Phát hiện và theo dõi vận động



Hình 2-8 : Mô hình nhận dạng hoạt động bất thường

Sau khi có được Model các hoạt động bình thường là kết quả đầu ra của quá trình huấn luyện. Dữ liệu nhận về từ cảm biến WAX3 nhận về được trích chọn đặc trưng. Từ các đặc trưng này được phân loại là hoạt động bình thường hay hoạt động bất thường từ Model các hoạt động bình thường.

Với giải pháp thứ nhất, trích chọn đặc trưng bằng cách chia dữ liệu cảm biến nhận được (x1, y1, z1, x2, y2, z2) ra thành các cửa sổ. Mỗi cửa sổ gồm 50 bộ dữ

liệu để tính toán các giá trị đặc trưng để tạo thành vector đặc trưng. Từ vector đặc trưng thu được, sử dụng mô hình học máy One Class SMV để phân loại hoạt động bất thường hay bình thường.

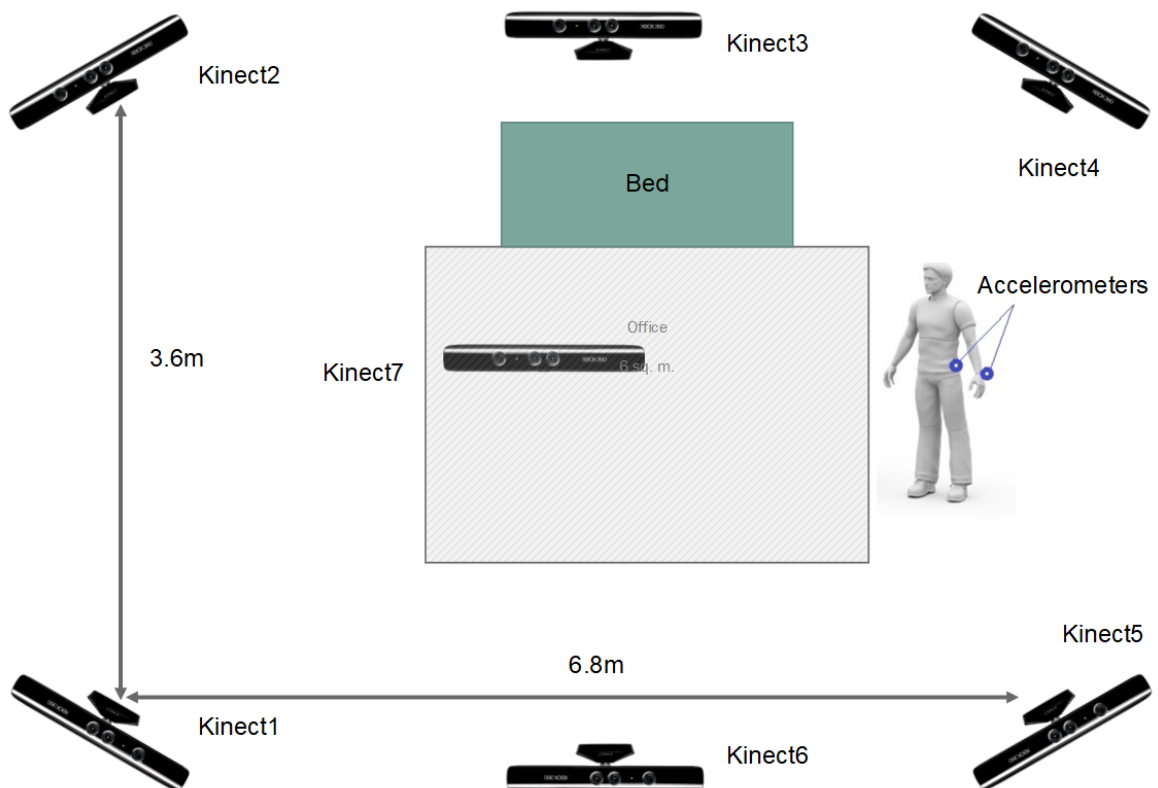
Với giải pháp thứ 2, trích chọn đặc trưng bằng cách sử dụng các mô hình HMM của các hoạt động bình thường. Với mỗi một bộ dữ liệu từ cảm biến WAX3 ($x_1, y_1, z_1, x_2, y_2, z_2$), tính toán giá trị log-likelihood từ các mô hình HMM của các hoạt động bình thường. Sau khi tính toán thu được vector đặc trưng $x_i = (L(x_1; \lambda_1), \dots, L(z_2; \lambda_M))$. Từ các vector đặc trưng này, ta sử dụng thuật toán One Class SMV để phân loại hoạt động bất thường hay bình thường.

CHƯƠNG 3: THỰC NGHIỆM VÀ ĐÁNH GIÁ

Chương này trình bày về quá trình thu thập dữ liệu về một số hoạt động để tạo tập dữ liệu mẫu. Tiếp theo chương trình bày về đánh giá phương pháp phát hiện hoạt động bất thường ở chương 2.

3.1. Thu thập dữ liệu

Luận văn sử dụng bộ dữ liệu CMDFALL. Đây là một tập dữ liệu đa thể thức nhằm đến mục đích phân tích ngã, phát hiện người ngã, là một nghiên cứu chung đến từ hai trường Học viện Công nghệ Bưu chính Viễn thông và Đại học Bách Khoa Hà Nội. Trong quá trình thu dữ liệu, hai cảm biến gia tốc WAX3 được sử dụng để thu dữ liệu từ 50 người. Các thiết bị ghi hình Kinect được đặt tại nhiều vị trí khác nhau xung quanh phòng, trong khi hai cảm biến gia tốc được đeo trên cổ tay trái và hông trái của người thu dữ liệu.



Hình 3-1: Bố trí, lắp đặt môi trường và thiết bị thu dữ liệu trong bộ CMDFALL

Để phục vụ cho mục đích sử dụng đa thể thức, dữ liệu từ tất cả thiết bị đều được gắn kèm nhãn thời gian với độ chia nhỏ nhất là 1 mili giây, tạo sự thuận tiện cho việc đồng bộ theo thời gian các luồng dữ liệu với nhau. Có tổng cộng 17 hoạt động được chia thành 2 nhóm hoạt động bình thường và nhóm hoạt động bất thường, chi tiết như trong dưới đây

2 nhóm	ID	17 hoạt động
Không ngã (Hoạt động bình thường)	1	Đi bộ theo các hướng
	2	Chạy chậm
	3	Nhảy tại chỗ
	4	Cử động tay và đầu gối
	5	Cúi xuống nhặt đồ bằng tay trái
	6	Cúi xuống nhặt đồ bằng tay phải
	7	Đi loạng choạng
	8	Ngồi lên ghế rồi đứng lên
	9	Di chuyển ghế sang vị trí khác
	10	Ngồi lên giường rồi đứng lên
	11	Nằm lên giường rồi ngồi dậy
Ngã (Hoạt động bất thường)	12	Ngã về phía trước
	13	Ngã về phía sau
	14	Ngã về bên trái
	15	Ngã về bên phải
	16	Ngã về bên trái khi đang ngồi trên ghế
	17	Ngã về bên phải khi đang ngồi trên ghế

Bảng 3-1 : Danh sách các hoạt động

3.2.Thử nghiệm và đánh giá

Các thước đo đánh giá bao gồm:

- Confusion matrix: hay còn gọi là ma trận lỗi, là một khái niệm trong học máy cho phép mô phỏng về hoạt động của một thuật toán dưới dạng bảng. Mỗi cột của ma trận đại diện cho các instance của 1 lớp dự đoán, trong khi mỗi hàng đại diện cho các vector đặc trưng trong một lớp thực tế.

Nó có dạng:

Lớp Ci	Lớp dự đoán		
Lớp thực tế		Lớp = YES	Lớp = NO
	Lớp = YES	True positive(TP)	False positive(FP)
	Lớp = NO	False negative(FN)	True negative(TN)

Bảng 3-2 : Bảng ma trận confusion

+ TP : số lượng các ví dụ thuộc lớp hoạt động bình thường được phân loại đúng vào lớp hoạt động bình thường.

+ FP : số lượng các ví dụ không thuộc lớp hoạt động bình thường được phân vào lớp hoạt động bình thường.

+ TN : số lượng các ví dụ thuộc lớp hoạt động bất thường được phân vào lớp hoạt động bất thường.

+ FN : số lượng các ví dụ không thuộc lớp hoạt động bất thường được phân vào lớp hoạt động bất thường.

- Tỷ lệ lớp được nhận dạng chính xác (true positive + true negative): Tỷ lệ theo phần trăm số vector đặc trưng được gán lớp đúng trên tổng số vector đặc trưng được kiểm thử

- Tỷ lệ lớp được nhận dạng không chính xác(false positive + false negative): Tỷ lệ theo phần trăm số vector đặc trưng được gán lớp sai trên tổng số vector đặc trưng được kiểm thử.
- **accuracy** : Đó là tỷ lệ của các đối tượng được dán nhãn chính xác cho toàn bộ nhóm đối tượng.

$$\text{accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (3.1)$$

- **Precision và recall** hay còn gọi là độ chính xác và độ bao phủ.

Precision - độ chính xác : xác định các phần của hồ sơ mà thực sự hóa ra là tích cực trong các nhóm phân loại. Tính bằng tổng số các ví dụ thuộc lớp Ci phân loại chính xác chia cho tổng số các ví dụ được phân loại vào lớp ci.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3.2)$$

Recall - độ bao phủ : phần trăm các trường hợp tích cực là TP rate, được tính bằng tổng số các ví dụ thuộc lớp Ci được phân loại chính xác chia cho tổng số các ví dụ thuộc lớp Ci.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.3)$$

Recall cũng được gọi là True Positive Rate hay Sensitivity (độ nhạy), và Precision cũng được gọi là Positive Predictive Value (PPV); Ngoài ra ta có các độ đo khác như True Negative Rate và Accuracy. True Negative Rate cũng được gọi là Specificity.

- **Độ đo F1 :**

Tiêu chí đánh giá F1 là sự kết hợp của 2 tiêu chí đánh giá Precision và Recall

$$F = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3.4)$$

F1 là một trung bình điều hòa (harmonic mean) của các tiêu chí Precision và Recall.

- F1 có xu hướng lấy giá trị gần với giá trị nào nhỏ hơn giữa 2 giá trị Precision và Recall.

- F1 có giá trị lớn nếu cả 2 giá trị Precision và Recall đều lớn.

3.3. Kết quả

Phương pháp thứ nhất, các đặc trưng được trích chọn bằng cách chia bộ dữ liệu ra thành các cửa sổ. Mỗi cửa sổ 50 bộ dữ liệu cảm biến trong tập dữ liệu. Tính toán các đặc trưng : Trung bình cộng, độ lệch chuẩn, Entropy thông tin, độ tương quan của dữ liệu. Bộ dữ liệu các hoạt động bình thường gồm 400.000 bộ dữ liệu cho các hoạt động bình thường. Chia thành các cửa sổ, mỗi cửa sổ 50 bộ dữ liệu. Tổng số cửa sổ của hoạt động bình thường là 8000. Dữ liệu hoạt động bất thường được sử dụng để kiểm tra gồm 15.000 bộ dữ liệu, tổng số cửa sổ của hoạt động bất thường là 300. Kết quả của phương pháp này cho bởi bảng sau :

Ma trận lỗi :

Với :

1 : Ngã về phía trước

2 : Ngã về phía sau

3 : Ngã về bên trái

4 : Ngã về bên phải

5 : Ngã về bên trái khi đang ngồi trên ghế

6 : Ngã về bên phải khi đang ngồi trên ghế

7 : Các hoạt động khác (Hoạt động bình thường)

	1	2	3	4	5	6	7
1	204	0	0	0	0	0	96
2	0	210	0	0	0	0	90

3	0	0	211	0	0	0	89
4	0	0	0	213	0	0	87
5	0	0	0	0	190	0	110
6	0	0	0	0	0	202	98
7	109	109	109	109	109	109	191

Bảng 3-3: Mã trộn lỗi giải pháp thứ nhất

Bảng kết quả tính toán các độ đo :

	Precision	Recall	F11
1	0.68	0.65	0.66
2	0.70	0.66	0.68
3	0.70	0.66	0.68
4	0.71	0.68	0.68
5	0.63	0.64	0.63
6	0.67	0.65	0.66

Bảng 3-4 : Kết quả giải pháp thứ nhất

Phương pháp thứ hai, Sử dụng HMM để trích chọn đặc trưng. Với bộ dữ liệu kiểm tra gồm 3000 bộ dữ liệu bất thường và 3000 bộ dữ liệu hoạt động bình thường để kiểm tra. Kết quả phương pháp :

Ma trận lỗi :

Với :

1 : Ngã về phía trước

2 : Ngã về phía sau

3 : Ngã về bên trái

4 : Ngã về bên phải

5 : Ngã về bên trái khi đang ngồi trên ghế

6 : Ngã về bên phải khi đang ngồi trên ghế

7 : Các hoạt động khác (Hoạt động bình thường)

	1	2	3	4	5	6	7
1	2590	0	0	0	0	0	410
2	0	2550	0	0	0	0	450
3	0	0	2597	0	0	0	403
4	0	0	0	2696	0	0	304
5	0	0	0	0	2135	0	865
6	0	0	0	0	0	2493	507
7	1491	1491	1491	1491	1491	1491	1509

Bảng 3-5 : Mã trộn lỗi giải pháp thứ nhất

Bảng kết quả tính toán các độ đo :

	Precision	Recall	F11
1	0.86	0.63	0.73
2	0.85	0.63	0.72
3	0.87	0.63	0.73

4	0.90	0.64	0.75
5	0.71	0.59	0.64
6	0.83	0.62	0.71

Bảng 3-6 : Kết quả giải pháp thứ 2

Từ kết quả thực nghiệm cho thấy, Phương pháp trích chọn đặc trưng sử dụng HMM cho kết quả tốt hơn. Kết quả các độ đo của phương pháp trích chọn đặc trưng bằng HMM có độ chính xác cao hơn. Phân loại được các hoạt động bình thường và bất thường tốt hơn.

Trong cả hai phương pháp thực nghiệm cho thấy, hoạt động bất thường “Ngã về bên phải” cho điểm số cao nhất. Phương pháp trích chọn đặc trưng bằng chia cửa sổ cho độ đo F1 là 0.68, phương pháp trích chọn đặc trưng bằng mô hình HMM cho độ đo F1 là 0.75. Điều này lý giải là do các cảm biến gắn ở vòng đeo tay thông minh và dây thắt lưng thông minh đều ở phía bên phải nên khi ngã ở tư thế đang đứng về phía bên phải cho dữ liệu cảm biến gia tốc dễ nhận biết nhất.

Tuy nhiên cũng là ngã về bên phải nhưng tư thế đang ngồi ghé cho điểm số thấp nhất. Phương pháp trích chọn đặc trưng bằng chia cửa sổ cho độ đo F1 là 0.63, phương pháp trích chọn đặc trưng bằng HMM cho độ đo F1 là 0.64. Tại vì khi ngồi trên ghế ngã về bên phải, cả hai cảm biến trên vòng đeo tay thông minh và dây thắt lưng thông minh đều ở gần nhau, và khi ngã về bên phải, dữ liệu cảm biến nhận về dễ bị nhầm lẫn sang các hoạt động bình thường khác như đi bộ chậm ...

III. KẾT LUẬN

Luận văn này tập trung nghiên cứu về các phương pháp nhận dạng hoạt động của con người, đồng thời áp dụng vào việc nghiên cứu các hoạt động phần tay và phần eo cơ thể con người. Dự kiến, luận văn đạt được một số kết quả sau:

- Thử nghiệm và đánh giá các phương pháp nhận dạng hoạt động của người và trên cơ sở đó lựa chọn phương pháp nhận dạng hoạt động phần tay và eo cơ thể của con người để phát hiện hoạt động bất thường.
- Xây dựng ứng dụng demo nhận dạng một số hoạt động bất thường cụ thể của con người.

Trong tương lai, luận văn có thể được tiếp tục nghiên cứu để có thể nhận dạng được nhiều hoạt động và hoạt động bất thường hơn nữa. Đồng thời, lựa chọn phương pháp tốt hơn để mang lại tính chính xác cao hơn.

IV. DANH MỤC CÁC TÀI LIỆU THAM KHẢO

- [1] “*Accurate Prediction of Energy Expenditure Using a Shoe-Based Activity Monitor*” của Nadezhda Sazonova, Raymond C. Browning, Và Edward Sazonov tại Department of Electrical and Computer Engineering, University of Alabama, Tuscaloosa, AL; và Department of Health and Exercise Science, Colorado State University, Fort Collins, CO
- [2] “*Detecting stereotypical motor movements in the classroom using accelerometry and pattern recognition algorithms*” của Fahd Albinali , Matthew S. Goodwin, Stephen Intille tại Massachusetts Institute of Technology, Cambridge, MA 02139, USA ;The Groden Center, Inc., Providence, RI 02906, USA ; Northeastern University, Boston, MA 02115, USA.
- [3] “*Pervasive Computing and Autism: Assisting Caregivers of Children with Special Needs*” của Julie A. Kientz, Gillian R. Hayes, Tracy L. Westeyn, Thad Starner and Gregory D. Abowd tại Georgia Institute of Technology.
- [4] “*Autism: recognition, referral diagnosis and management of adults on the autism spectrum*” của NICE clinical guideline 142 guidance.nice.org.uk/cg142
- [5] “*Sensor-based Abnormal Human-Activity Detection*” của Jie Yin, Qiang Yang, Senior Member, IEEE and Jeffrey Junfeng Pan
- [6] S. D. Bay and M. Schwabacher. Mining distance-based outliers in near linear time with randomization and a simple pruning rule. In *Proceedings of the Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*, Washington, DC, USA, August 2003.
- [7] G. Fumera and F. Roli. Cost-sensitive learning in support vector machines. In *In Proceedings of the Workshop on Machine Learning, Methods and Applications, held in the context of the Eighth Meeting of the Italian Association of Artificial Intelligence (AI*IA)*, Siena, Italy, September 2002

- [8] Jeffrey Junfeng Pan, James T. Kwok, Qiang Yang, and Yiqiang Chen. Multidimensional vector regression for accurate and low-cost location estimation in pervasive computing. *IEEE Transactions on Knowledge and Data Engineering*, 18(9):1181– 1193, 2006.
- [9] J. Yin, X. Chai, and Q. Yang. High-level goal recognition in a wireless LAN. In *Proceedings of the Nineteenth National Conference in Artificial Intelligence (AAAI)*, San Jose, CA, USA, July 2004.
- [10] B. Scholkopf, J. Platt, J. Shawe-Taylor, and A. Smola. Estimating the support of a high-dimensional distribution. *Neural Computation*, 13(7):1443–1471, July 2001
- [11] D.M.J. Tax and R.P.W. Duin. Support vector domain description. *Pattern Recognition Letters*, 20(1113):1191–1199, 1999.
- [12] Ms. Apurva Landge, PG Student, Department of Computer Engineering, SPCOE Otur, *A Smart Home Monitoring System for Abnormal Human Activity Detection Using SVM*, IJCSMC, Vol. 4, Issue. 12, December 2015, pg.15 – 29
- [13] H.Medjahed, D.Istrate, J.Bouny, and B.Dorizzi, “*Human activities of daily living recognition using fuzzy logic for elderly home monitoring*”, in proc. IEEE Int. Conf. Fuzzy Syst, aug 2009, pp.2001-2006
- [14] L. Bao and S. S. Intille. Activity recognition from user-annotated acceleration data. In *Proceedings of The International Conference on Pervasive Computing*, pages 1–17. Springer, 2004
- [15] Katherine A. Heller Krysta M. Svore Angelos D. Keromytis Salvatore J. Stolfo, *One Class Support Vector Machines for Detecting Anomalous Windows Registry Accesses*
- [16] M. Palatucci, D. Pomerleau, G. E. Hinton, and T. M. Mitchell. Zero-shot learning with semantic output codes. In *Proceedings of The Neural Information Processing Systems (NIPS)*, 2009