

PHÁT HIỆN HOẠT ĐỘNG BẤT THƯỜNG SỬ DỤNG HÀM NHÂN PHI TUYẾN HỒI QUI

Nguyễn Tuấn Linh⁺, Vũ Văn Thỏa⁺, Phạm Văn Cường⁺

⁺ Học viện Công nghệ Bưu chính Viễn thông

Abstract - Bài báo đề xuất một phương pháp phát hiện bất thường gồm hai giai đoạn, trong giai đoạn đầu tiên, SVM một lớp được thiết lập để lọc ra hầu hết các hoạt động bình thường; ở giai đoạn thứ 2, các dữ liệu bất thường được chuyển đến một tập hợp các mô hình hoạt động bất thường có điều chỉnh thông qua hàm nhân phi tuyến hồi quy để phát hiện thêm. Quá trình huấn luyện mô hình được thực hiện qua thuật toán kỳ vọng cực đại (EM). Chúng tôi cũng đã tiến hành thực nghiệm và đánh giá kết quả của phương pháp đề xuất trên tập dữ liệu thu thập từ 50 người gồm 20 hoạt động và vận động bất thường. Kết quả với độ chính xác và độ nhạy trung bình đạt được là 76.32% và 78.95% cho thấy nhiều tiềm năng ứng dụng cho các ứng dụng chăm sóc, hỗ trợ người cao tuổi, hoặc giám sát an ninh.

Keywords - Cảm biến, hoạt động bất thường, học máy.

I. GIỚI THIỆU

Tự động phát hiện các vận động bất thường nhận được nhiều sự quan tâm của cộng đồng nghiên cứu trong thời gian gần đây vì tiềm năng ứng dụng trong thực tế như trợ giúp theo dõi và chăm sóc sức khỏe cho người cao tuổi, cảnh báo an ninh, tự động phát hiện tai nạn v.v... Ví dụ như ở nơi công cộng (public space) cần được bám đạo an ninh trong khi có nhiều người đang tham dự sự kiện nào đó. Nếu có một hệ thống theo dõi các hoạt động của từng cá nhân và phát hiện được hoạt động bất thường thì hệ thống có thể khoanh vùng và gửi cảnh báo sớm đến lực lượng an ninh, từ đó sẽ hạn chế được các hậu quả của việc mất an toàn hoặc thậm chí khủng bố. Các nghiên cứu trước đây thường tập trung vào bài toán nhận dạng các hoạt động bình thường (hoạt động thường xuyên diễn ra) của người (human activity recognition) và đã thu được các kết quả đáng kể, trong đó các nghiên cứu [1][2][3] phân tích dữ liệu từ các cảm biến để huấn luyện các mô hình học máy hoặc học sâu [1], qua đó nhận dạng

các hoạt động của người. Trong khi đó, bài toán ngược là nhận dạng các hoạt động bất thường cũng có nhiều ứng dụng rộng rãi đặc biệt trong lĩnh vực an ninh và chăm sóc sức khỏe cho người cao tuổi. Chẳng hạn, đối với việc đảm bảo an ninh, giả sử cần theo dõi hoạt động của tất cả mọi người trong một khu vực cần bảo vệ đặc biệt, người ta có thể sử dụng thẻ định danh có gắn cảm biến, cảm biến này có thể theo dõi các hoạt động của người đeo thẻ, nếu có một hoạt động được coi là bất thường, hệ thống sẽ phát ra báo động cảnh báo về việc mất an ninh cho các bộ phận có liên quan. Hay trong lĩnh vực chăm sóc sức khỏe ở người cao tuổi, thay vì quan tâm đến các hoạt động bình thường của người dùng, các bác sỹ hoặc người chăm sóc sẽ đặc biệt quan tâm đến các hoạt động bất thường, có thể là ngã hay các hoạt động mất kiểm soát ở các bệnh nhân Parkinson.

Những hệ thống nhận dạng hoạt động bất thường có thể gặp khó khăn trong quá trình huấn luyện do dữ liệu về hoạt động bất thường rất khan hiếm. Ví dụ như đối với hệ thống an ninh bảo mật, việc giám sát có thể dễ dàng nhận biết các hoạt động bình thường có tính thường xuyên xảy ra do tính sẵn có của các dữ liệu này trong huấn luyện. Nhưng với các hoạt động bất thường, hệ thống khó nhận biết được do các hoạt động bất thường là mới mẻ với hệ thống. Hơn nữa, khi dữ liệu về hoạt động bất thường được sử dụng để huấn luyện thì hoạt động bất thường đó có thể bị thay đổi để tránh bị phát hiện. Đối với việc nhận dạng hoạt động bất thường, sự hạn chế của dữ liệu huấn luyện thường dẫn đến hiệu suất phát hiện hoạt động bất thường chưa đạt được độ chính xác đủ cao.

Trong bài báo này, chúng tôi mở rộng một phương pháp phân loại các hoạt động bất thường đơn giản dựa trên mô hình máy véc tơ hỗ trợ (support vector machines) [4] bằng việc sử dụng thuật toán lặp thích nghi dựa trên mô hình hồi quy phi tuyến với hàm nhân. Chúng tôi thực nghiệm trên một tập dữ liệu từ 50 người tham gia với 20 hoạt động khác nhau bao gồm cả các hoạt động bất thường do nhóm nghiên cứu tại Đại học Bách khoa Hà nội và Học viện Công nghệ Bưu chính Viễn thông thu thập và đã công bố tại Hội nghị quốc tế ICPR 2018 [5] và bước đầu cho kết quả

Tác giả liên hệ: Nguyễn Tuấn Linh
Email: nguyentlinhict@gmail.com
Đến tòa soạn: 04/2019, chỉnh sửa: 20/5/2019, chấp nhận đăng: 27/5/2019

tương đối khả quan.

II. CÁC NGHIÊN CỨU LIÊN QUAN

Trước đây, đã có một số nghiên cứu đề xuất các phương pháp để phát hiện hoạt động bất thường và thường tiếp cận theo ba hướng chính:

A. Nhận dạng hoạt động bất thường sử dụng học máy

Nghiên cứu [6] sử dụng việc khai thác các luật đơn giản được sử dụng để mô tả hành vi bình thường trong các hoạt động của con người. Tiếp cận theo hướng này có thể cung cấp một khả năng nắm bắt các quy tắc bất thường tốt bằng việc sử dụng các quy tắc đặc biệt được biểu diễn bởi kiến thức chuyên gia.

Nghiên cứu [7] tiếp cận bằng phương pháp kế hoạch mẫu nhận dạng (template-based plan recognition) cho ứng dụng giám sát bảo mật. Với phương pháp này, một kế hoạch mẫu được đề xuất để công nhận và xếp hạng các mẫu tiềm năng có khả năng dẫn đến một cuộc tấn công bất hợp pháp. Đầu tiên hệ thống tiến hành biên dịch một tập các mẫu điển hình bằng các khung logic để lập kế hoạch thông minh nhân tạo, sau đó hệ thống tiến hành kết hợp các mẫu này với các hành động và mục tiêu được giám sát. Cách tiếp cận như vậy chỉ đạt được tỷ lệ thành công cao khi các mẫu kế hoạch được định nghĩa là ưu tiên.

Nhiều nghiên cứu trước đây đã đề xuất các phương pháp dựa trên mô hình Markov ẩn (HMM) [8] hay mạng Bayesian động (DBNs) [9][10][11] trong phát hiện hoạt động của người. Ví dụ, Lester và đồng sự [8] đã nghiên cứu cách tiếp cận phân biệt lai để công nhận các hoạt động của người, trong đó các đặc trưng quan trọng được trích xuất để xây dựng một tập hợp các bộ phân loại tĩnh và HMM được huấn luyện để phát hiện các hoạt động khác nhau. Patterson và đồng sự đã áp dụng mạng Bayesian trong [9][11] để dự đoán về vị trí của con người và phương tiện di chuyển sử dụng GPS trong môi trường đô thị. Nghiên cứu của Yin và đồng sự [12] áp dụng DBN để phát hiện các hoạt động trong nhà của người từ các chuỗi giá trị cường độ tín hiệu mạng LAN. Trong [13] lại sử dụng micro và gia tốc kế để phát hiện các hoạt động hàng ngày của người. Điểm chung của các nghiên cứu kể trên là đều sử dụng phương pháp học có giám sát, các phương pháp này đòi hỏi một lượng lớn dữ liệu được gán nhãn để huấn luyện, do đó nếu sử dụng để phát hiện bất thường sẽ dẫn đến thiếu dữ liệu để huấn luyện.

Một số nghiên cứu sử dụng phương pháp thị giác máy để phát hiện hoạt động bất thường trong video. Xiang và đồng sự [14] sử dụng một DBN để mô hình hóa từng loại mẫu video bình thường. Ở đây, một hoạt

động được coi là bất thường nếu khả năng nó được nhận dạng bởi các mô hình bình thường nhỏ hơn ngưỡng. Đây là hướng nghiên cứu khá đơn giản và hấp dẫn, tuy nhiên việc xác định ngưỡng thế nào là hợp lý là một điều khó khăn. Nghiên cứu [15][37] sử dụng mô hình Markov ẩn để phát hiện hoạt động bất thường trong chu kỳ trạng thái, đây cũng là hướng tiếp cận mang lại các kết quả khả thi.

B. Phát hiện hoạt động bất thường sử dụng học máy kết hợp khai phá dữ liệu

Đây là hướng tiếp cận sử dụng các kiến thức về học máy và khai phá dữ liệu để phát hiện mẫu ngoại lệ hay ngoại lai (outlier). Ở hướng tiếp cận này có thể được chia thành hai nhánh: Thứ nhất là tiếp cận dựa trên sự tương đồng [16], thứ hai là tiếp cận dựa trên mô hình [17][18].

Trong nghiên cứu của Breunig và đồng sự [19] lại sử dụng học máy kết hợp với khai phá dữ liệu để nhận dạng hoạt động bất thường, các tác giả đã sử dụng phân cụm dựa trên mật độ để phát hiện các ngoại lai cục bộ, thuật toán này thường dựa vào khoảng cách và ngưỡng mật độ do người dùng xác định để phát hiện sự xuất hiện của các ngoại lai (hoặc các điểm dữ liệu bất thường) trong không gian nhiều chiều (high-dimensional space). Nguyên lý của phương pháp là nếu các điểm lân cận gần nhau thì mẫu được coi là bình thường, ngược lại mẫu được coi là bất thường. Phương pháp này có ưu điểm là không cần phải xác định phân phối để xác định ngoại lai và có thể thực hiện trên một tập dữ liệu lớn. Thế nhưng khó khăn là làm thế nào để xác định tính tương đồng một cách hiệu quả với một lượng dữ liệu lớn và không chắc chắn. Có thể lấy ví dụ trong một khu vực mạng cảm biến, các thông số cảm biến liên tục thay đổi theo thời gian. Do đó rất khó xác định một khoảng cách đủ mạnh để tìm ra các điểm dữ liệu ngoại lai. Một khó khăn khác trong trường hợp hệ thống cần phải hoạt động trực tuyến thì các mô hình phải được huấn luyện trước khi các hoạt động bất thường xảy ra, điều này là không khả thi. Hơn nữa, khi có một lượng dữ liệu lớn mang tính đa dạng và ngẫu nhiên thì các phương pháp tiếp cận theo hướng tương đồng và dựa trên khoảng cách thường khó có thể hoạt động tốt như mong muốn.

Nghiên cứu của Ma và Parkins [18] tiếp cận việc phát hiện hoạt động bất thường bằng các mô hình dự báo, trước tiên họ tiến hành trích xuất các đặc trưng hữu ích từ dữ liệu chuỗi thời gian (time series data), sau đó tiến hành huấn luyện mô hình SVM một lớp để phát hiện dữ liệu ngoại lai. Điểm hạn chế của cách tiếp cận theo hướng này là việc lựa chọn một tham số có độ nhạy thích hợp để đạt được sự cân bằng hợp lý giữa độ chính xác và cảnh báo giả (false alarm).

C. Phát hiện hoạt động bất thường sử dụng huấn luyện có trọng số

Một số nghiên cứu tiếp cận theo hướng huấn luyện có trọng số (Cost-sensitive learning). Đây là hướng nghiên cứu nhằm giải quyết các vấn đề phân loại trong sự hiện diện của các trọng số phân loại sai khác nhau có liên quan đến các lỗi [17][20] và rất hữu ích cho việc huấn luyện trong trường hợp các lớp là không cân bằng. Vấn đề về trọng số phân loại sai khác nhau rất phổ biến trong nhiều lĩnh vực đời sống như chẩn đoán y khoa, phát hiện xâm nhập hay tiếp thị trực tiếp. Điển hình có các nghiên cứu [17][21] đã chứng minh việc sử dụng các chỉ số đánh giá dựa trên xếp hạng theo đường cong đặc trưng hoạt động của bộ thu nhận (Receiver Operating Characteristic - ROC) thay vì sử dụng độ chính xác. Trong [22][23] Yang và đồng sự giới thiệu một cách tiếp cận tích hợp huấn luyện có trọng số với xử lý giá trị còn thiếu (missing value handling) nơi có thêm trọng số kiểm tra tồn tại (where additional test costs exist) khi thu được giá trị còn thiếu cho dữ liệu tương lai.

Kỹ thuật huấn luyện có trọng số thường được sử dụng để giải quyết các vấn đề về dữ liệu mất cân bằng, bằng cách thiết lập các trọng số false positive và false negative khác nhau và kết hợp các yếu tố trọng số trong một risk formula [17][24] (tạm dịch: hàm rủi ro). Các nghiên cứu về huấn luyện có trọng số có ba nhóm chính. Nhóm đầu tiên tập trung vào việc phân loại cụ thể huấn luyện có trọng số bao gồm các phương pháp sử dụng cây quyết định [25], mạng nơron [26] và máy vecto hỗ trợ (SVM) [27]. Nhóm thứ hai thiết kế trình bao bọc cho bất kỳ thuật toán phân loại nào bằng việc áp dụng lý thuyết Bayes và gán cho mỗi mẫu trọng số lớp thấp nhất của nó [24]. Nhóm thứ ba bao gồm các phương pháp huấn luyện sửa đổi phân phối các mẫu (modify the distribution of training examples) trước khi áp dụng các thuật toán để các phân loại học được từ bản phân phối đã sửa đổi là nhạy cảm về trọng số [28].

III. PHƯƠNG PHÁP PHÁT HIỆN VẬN ĐỘNG BẤT THƯỜNG

Thực tế cho thấy rằng, đối với các hoạt động bất thường, việc thu thập một lượng lớn dữ liệu cho huấn luyện mô hình là khá khó khăn nhưng lại dễ dàng thực hiện điều này với các hoạt động bình thường, điều này cho phép tạo ra các mô hình nhận dạng với kết quả tốt với hoạt động bình thường. Do đó, chúng tôi thực hiện một phương pháp phát hiện hoạt động bất thường gồm hai giai đoạn với dữ liệu huấn luyện có sẵn của các hoạt động bình thường. Ở giai đoạn thứ nhất, chúng tôi xây dựng một máy véc tơ hỗ trợ một lớp (One-Class SVM) chỉ dựa trên dữ liệu của các hoạt động bình thường để lọc ra các hoạt động có xác suất cao là bình thường, trong đó mỗi hoạt động bình thường

được mô hình hóa bởi một mô hình Markov ẩn tương tự cách trích chọn và biểu diễn đặc trưng trong các nghiên cứu [32] [33] [34] [35] [36] [37]. Các dấu hiệu đáng ngờ, còn phân vân được chuyển tiếp sang giai đoạn hai để phát hiện thêm. Ở giai đoạn thứ hai, chúng tôi sử dụng phân tích hồi quy không tuyến tính để phát hiện ra các mô hình hoạt động bất thường từ một mô hình hoạt động bình thường. Với phương pháp tiếp cận này, chúng tôi có thể đạt được một tỷ lệ phát hiện hoạt động bất thường khá tốt mà không cần phải thu thập và ghi nhận dữ liệu bất thường một cách rõ ràng. Chúng tôi tiến hành thu thập dữ liệu từ nhiều cảm biến đeo trên cơ thể người dùng và chứng minh tính hiệu quả cách tiếp cận của chúng tôi bằng cách sử dụng các dữ liệu này trong thực tế.

A. Huấn luyện mô hình bằng thuật toán kỳ vọng tối đa (EM)

Cho X là vecto ngẫu nhiên từ một tập hợp được tham số hóa, muốn tìm θ sao cho $P(X|\theta)$ là cực đại. Yêu cầu này được gọi là ước tính tối đa khả năng Maximum Likelihood (ML) cho θ . Để ước tính θ , hàm hợp lý log (log likelihood function) được định nghĩa là:

$$L(\theta) = \ln P(X|\theta) \quad (1)$$

Hàm likelihood được coi là hàm của tham số θ cho dữ liệu X . Vì $\ln(x)$ là một hàm gia tăng nghiêm ngặt, giá trị của θ tối đa hóa cho $P(X|\theta)$ cũng tối đa cho $L(\theta)$.

Thuật toán EM là một thủ tục lặp để tối đa hóa $L(\theta)$. Giả sử rằng sau lần lặp thứ n ước tính hiện tại cho θ được đưa ra bởi θ_n . Vì mục tiêu là để tối đa hóa $L(\theta)$, muốn tính toán một ước tính cập nhật θ thì:

$$L(\theta) > L(\theta_n) \quad (2)$$

Tương tự, muốn tối đa hóa sự khác biệt:

$$L(\theta) - L(\theta_n) = \ln P(X|\theta) - \ln P(X|\theta_n) \quad (3)$$

Trong các vấn đề về tồn tại dữ liệu, thuật toán EM cung cấp một khuôn khổ tự nhiên cho sự bao hàm của chúng. Nói cách khác, các biến ẩn có thể được giới thiệu hoàn toàn như một thủ thuật để ước tính khả năng tối đa θ để kiểm soát. Trong trường hợp này, giả định rằng việc biết rõ về các biến ẩn sẽ làm cho việc tối đa hóa hàm có khả năng dễ dàng hơn. Có nghĩa là, biểu diễn các vecto ngẫu nhiên ẩn bởi Z và

được thể hiện bởi bởi z . Tổng xác suất $P(X|\theta)$ có thể được viết theo các biến ẩn z như sau:

$$P(X|\theta) = \sum_z P(X|z, \theta)P(z|\theta)$$

(4)

Công thức (3) có thể được viết lại như sau:

$$L(\theta) - L(\theta_n) = \ln \sum_z P(X|z, \theta)P(z|\theta) - \ln P(X|\theta_n)$$

(5)

Lưu ý rằng biểu thức này liên quan đến logarit của một tổng. Sử dụng Jensen's inequality, nó đã được chứng minh rằng:

$$\ln \sum_{i=1}^n \lambda_i x_i \geq \sum_{i=1}^n \lambda_i \ln(x_i)$$

cho hằng số $\lambda_i \geq 0$ với $\sum_{i=1}^n \lambda_i = 1$. Kết quả này có thể được áp dụng cho công thức (5) liên quan đến logarit của tổng được cung cấp các hằng số λ_i có thể được xác định. Xem xét để cho các hằng số có dạng $P(z|X, \theta_n)$. Vì $P(z|X, \theta_n)$ là một thước đo xác suất, chúng ta có $P(z|X, \theta_n) \geq 0$ và $\sum_z P(z|X, \theta_n) = 1$ theo yêu cầu.

Sau đó bắt đầu với công thức (5) hằng số $P(z|X, \theta_n)$ được đưa ra:

$$\begin{aligned} L(\theta) - L(\theta_n) &= \ln \sum_z P(X|z, \theta)P(z|\theta) - \ln P(X|\theta_n) \\ &= \ln \sum_z P(X|z, \theta)P(z|\theta) \cdot \frac{P(z|X, \theta_n)}{P(z|X, \theta_n)} - \ln P(X|\theta_n) \\ &= \ln \sum_z P(x|X, \theta) \left(\frac{P(X|z, \theta)P(z|\theta)}{P(z|X, \theta_n)} \right) - \ln P(X|\theta_n) \\ &\geq \sum_z P(z|X, \theta_n) \ln \left(\frac{P(X|z, \theta)P(z|\theta)}{P(z|X, \theta_n)} \right) - \ln P(X|\theta_n) \\ &= \sum_z P(z|X, \theta_n) \ln \left(\frac{P(X|z, \theta)P(z|\theta)}{P(z|X, \theta_n)P(X|\theta_n)} \right) \end{aligned}$$

Sau đó bắt đầu với công thức (5) hằng số $P(z|X, \theta_n)$ được đưa ra:

$$\begin{aligned} L(\theta) - L(\theta_n) &= \ln \sum_z P(X|z, \theta)P(z|\theta) - \ln P(X|\theta_n) \\ &= \ln \sum_z P(X|z, \theta)P(z|\theta) \cdot \frac{P(z|X, \theta_n)}{P(z|X, \theta_n)} - \ln P(X|\theta_n) \\ &= \ln \sum_z P(x|X, \theta) \left(\frac{P(X|z, \theta)P(z|\theta)}{P(z|X, \theta_n)} \right) - \ln P(X|\theta_n) \\ &\geq \sum_z P(z|X, \theta_n) \ln \left(\frac{P(X|z, \theta)P(z|\theta)}{P(z|X, \theta_n)} \right) - \ln P(X|\theta_n) \\ &= \sum_z P(z|X, \theta_n) \ln \left(\frac{P(X|z, \theta)P(z|\theta)}{P(z|X, \theta_n)P(X|\theta_n)} \right) \\ &\stackrel{\Delta}{=} \Delta(\theta|\theta_n) \end{aligned} \tag{6}$$

Chúng ta có thể viết lại tương đương:

$$L(\theta) \geq L(\theta_n) + \Delta(\theta|\theta_n) \tag{7}$$

và để thuận tiện cho xác định:

$$l(\theta|\theta_n) \stackrel{\Delta}{=} L(\theta_n) + \Delta(\theta|\theta_n)$$


để mỗi quan hệ trong công thức (7) có thể được thể hiện rõ ràng:

$$L(\theta) \geq l(\theta|\theta_n)$$

Bây giờ chúng ta có một hàm $l(\theta|\theta_n)$ được giới hạn trên bởi hàm $L(\theta)$. Ngoài ra, có thể quan sát:

$$\begin{aligned} l(\theta_n|\theta_n) &= L(\theta_n) + \Delta(\theta_n|\theta_n) \\ &= L(\theta_n) + \sum_z P(z|X, \theta_n) \ln \frac{P(X|z, \theta_n)P(z|\theta_n)}{P(z|X, \theta_n)P(X|\theta_n)} \\ &= L(\theta_n) + \sum_z P(z|X, \theta_n) \ln \frac{P(X, z|\theta_n)}{P(X, z|\theta_n)} \\ &= L(\theta_n) + \sum_z P(z|X, \theta_n) \ln 1 \\ &= L(\theta_n) \end{aligned} \tag{8}$$

vì vậy đối với $\theta = \theta_n$ các hàm $l(\theta|\theta_n)$ và $L(\theta)$ bằng nhau.



Hình 1. Biểu diễn đồ họa một lần lặp của thuật toán EM: Hàm $L(\theta|\theta_n)$ bị giới hạn trên bởi hàm $L(\theta)$. Các hàm có kết quả $\theta = \theta_n$. Thuật toán EM chọn θ_{n+1} làm giá trị của θ mà $l(\theta|\theta_n)$ là cực đại. Vì

$L(\theta) \geq l(\theta|\theta_n)$ tăng $l(\theta|\theta_n)$ đảm bảo rằng giá trị của hàm $L(\theta)$ khả năng được tăng lên ở mỗi bước.

Mục tiêu của chúng tôi là chọn một giá trị θ sao cho $L(\theta)$ cực đại. Nghiên cứu chỉ ra rằng hàm $l(\theta|\theta_n)$ bị giới hạn ở trên bởi hàm $L(\theta)$ và giá trị của các hàm $l(\theta|\theta_n)$ và $L(\theta)$ bằng với ước tính hiện tại tại cho $\theta = \theta_n$. Vì vậy, bất kỳ θ làm tăng $l(\theta|\theta_n)$ sẽ lần lượt tăng $L(\theta)$. Để đạt được sự gia tăng lớn nhất có thể về giá trị của $L(\theta)$, thuật toán EM được gọi để lựa chọn θ sao cho $l(\theta|\theta_n)$ được cực đại. chúng tôi biểu thị giá trị được cập nhật này là θ_{n+1} . Quá trình này được minh họa trong hình (1). Từ đó ta có:

$$\theta_{n+1} = \arg \max_{\theta} \{l(\theta|\theta_n)\}$$

$$\theta_{n+1} = \arg \max_{\theta} \left\{ L(\theta_n) + \sum_x P(z|X, \theta_n) \ln \frac{P(X|z, \theta)P(z|\theta)}{P(X|\theta_n)P(z|X, \theta_n)} \right\}$$

Bây giờ, giảm các hằng số w.r.t. θ

$$= \arg \max_{\theta} \left\{ \sum_x P(z|X, \theta_n) \ln P(X|z, \theta)P(z|\theta) \right\}$$

$$= \arg \max_{\theta} \left\{ \sum_x P(z|X, \theta_n) \ln \frac{P(X, z, \theta)}{P(z, \theta)} \frac{P(z, \theta)}{P(\theta)} \right\}$$

$$= \arg \max_{\theta} \left\{ \sum_x P(z|X, \theta_n) \ln P(X, z|\theta) \right\}$$

$$= \arg \max_{\theta} \left\{ E_{Z|X, \theta_n} \{ \ln P(X, z|\theta) \} \right\} \quad (9)$$

Trong công thức (9) các bước kỳ vọng và tối đa là rõ ràng. Do đó, thuật toán EM bao gồm việc lặp lại:

1. E-step: Xác định kỳ vọng có điều kiện

$$E_{Z|X, \theta_n} \{ \ln P(X, z|\theta) \}$$

2. M-step: Tối đa hóa biểu diễn liên quan đến θ

Tại thời điểm này, đề yêu cầu những gì đã đạt được khi cho rằng chúng tôi đã chỉ đơn giản là trao đổi tối đa hóa $L(\theta)$ cho tối đa hóa $l(\theta|\theta_n)$. Câu trả lời thực tế là $l(\theta|\theta_n)$ tính đến dữ liệu không được quan sát hoặc bị thiếu dữ liệu Z . Trong trường hợp chúng tôi ước tính các biến này, các thuật toán EM cung cấp một nền tảng cho việc này. Ngoài ra, như đã đề cập trước đó, khá thuận lợi để đưa ra các biến ẩn để tối đa hóa $l(\theta|\theta_n)$, điều này được đơn giản hóa nhờ kiến thức về các biến ẩn (so với tối đa hóa trực tiếp của $L(\theta)$).

Các tính chất hội tụ của thuật toán EM được đề xuất bởi McLachlan và Krishnan [29]. Trong phần này chúng tôi xem xét sự hội tụ chung của thuật toán. Vì θ_{n+1} là ước tính cho θ tối đa hóa sự khác biệt $\Delta(\theta|\theta_n)$. Bắt đầu với ước tính hiện tại cho θ , đó là θ_n , chúng tôi đã có $\Delta(\theta|\theta_n) = 0$. Vì θ_{n+1} được chọn để tối đa hóa $\Delta(\theta|\theta_n)$ và sau đó lại có $\Delta(\theta_{n+1}|\theta_n) \geq \Delta(\theta_n|\theta_n) = 0$, do đó đối với mỗi lần lặp, khả năng $L(\theta)$ là không thay đổi.

Khi thuật toán đạt đến một điểm cố định cho một vài θ_n giá trị θ_n tối đa hóa $l(\theta)$. Vì L và l bằng nhau

tại θ_n nếu L và l có khả năng khác nhau tại θ_n thì θ_n phải là một điểm dừng của L . Điểm dừng là không cần thiết, tuy nhiên là cực đại cục bộ. Trong [29] cho thấy rằng có thể cho các thuật toán hội tụ đến cực tiểu địa phương hoặc điểm yên trong trường hợp bất thường.

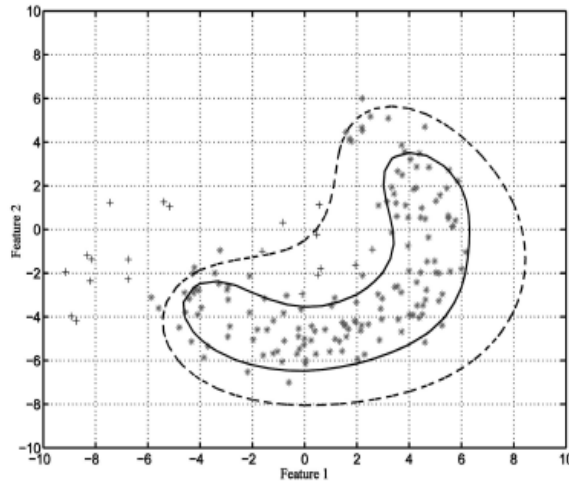
Trong thuật toán EM mô tả ở trên, θ_{n+1} được chọn làm giá trị θ với $\Delta(\theta|\theta_n)$ cực đại hóa. Trong khi điều này đảm bảo sự gia tăng lớn nhất trong $L(\theta)$, tuy nhiên nó có thể làm nhẹ bởi yêu cầu tối đa hóa một trong những $\Delta(\theta|\theta_n)$ sao cho $\Delta(\theta_{n+1}|\theta_n) \geq \Delta(\theta_n|\theta_n)$. Với cách tiếp cận này, chi đơn giản là tăng và không nhất thiết phải tối đa hóa $\Delta(\theta_{n+1}|\theta_n)$ được gọi là thuật toán tối đa hóa kỳ vọng tổng quát (GEM) và thường hữu ích trong trường hợp việc tối đa hóa là khó khăn. Sự hội tụ của thuật toán GEM có thể được lập luận như trên.

Sau khi chuyển đổi n dấu vết huấn luyện thành một tập hợp các vector đặc trưng x_1, \dots, x_n , chúng tôi huấn luyện một SVM một lớp dựa trên dữ liệu bình thường. Ý tưởng cơ bản là tìm một khu vực hình cầu chứa hầu hết các dữ liệu bình thường sao cho bán kính R tương ứng có thể là nhỏ nhất:

$$\begin{aligned} \min R^2 + C \sum_{i=1}^n \xi_i \\ \text{s.t. } \|c - x_i\|^2 \leq R^2 + \xi_i \\ \xi_i \geq 0 \end{aligned} \quad (10)$$

Ở đây, các biến ξ_i được sử dụng để cho phép một số điểm dữ liệu nằm bên ngoài hình cầu và tham số $C \geq 0$ điều khiển sự cân bằng giữa số lượng của hình cầu và số lỗi. Sử dụng biểu diễn kép của hàm Lagrange, hàm mục tiêu tương đương với:

$$\begin{aligned} \max \sum_{i=1}^n \alpha_i (x_i, x_i) - \sum_{i,j=1}^n \alpha_i \alpha_j (x_i, x_j) \\ \text{s.t. } 0 \leq \alpha_i \leq C, \sum_{i=1}^n \alpha_i = 1 \end{aligned} \quad (11)$$



Hình 2. SVM một lớp

Bài toán trên có thể được giải quyết bằng cách sử dụng các kỹ thuật tối ưu hóa tiêu chuẩn [30]. Để xác định xem dữ liệu thử nghiệm có nằm trong hình cầu hay không, khoảng cách tới tâm của hình cầu phải được tính toán. Nếu khoảng cách này nhỏ hơn bán kính R , thì dữ liệu thử nghiệm được coi là bình thường.

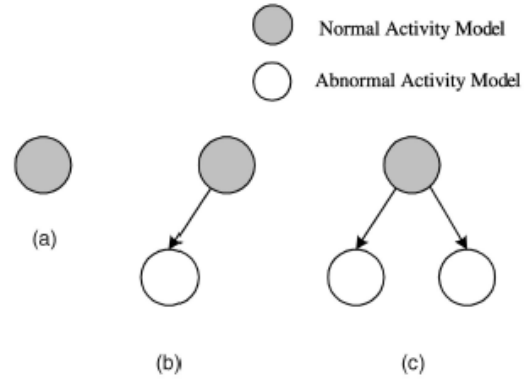
Thông thường, dữ liệu huấn luyện không được phân phối theo hình cầu trong không gian đầu vào. Do đó, các điểm dữ liệu ban đầu được ánh xạ đầu tiên vào một không gian đặc trưng để có thể thu được mô tả dữ liệu tốt hơn. Thay vì yêu cầu một hàm ánh xạ rõ ràng từ không gian đầu vào đến không gian đặc trưng, giải pháp có thể thu được bằng cách thay thế tất cả các kết quả bên trong $\langle \cdot, \cdot \rangle$ trong (3) bởi một hàm hạt nhân $k(\cdot, \cdot)$:

$$\max \sum_{i=1}^n \alpha_i k(x_i, x_i) - \sum_{i,j=1}^n \alpha_i \alpha_j k(x_i, x_j) \quad (12)$$

Trong trường hợp này, do các đặc tính phi tuyến và nhiều của các tham biến, ranh giới phân biệt của trình phân loại SVM một lớp có thể khá phức tạp. Do đó, chúng tôi sử dụng một hạt nhân Gaussian Radial Basis Function (RBF) cho SVM một lớp như sau:

$$k(x_i, x_j) = \exp(-\omega_1^2 \|x_i - x_j\|^2) \quad (13)$$

Ở đây ω_1 là một yếu tố mở rộng kiểm soát độ rộng của hàm hạt nhân.



Hình 3. Thủ tục thích nghi lặp lại

Một hạn chế lớn của việc sử dụng SVM một lớp để phát hiện bất thường là khó khăn trong việc chọn độ nhạy đủ cao để mang lại tỷ lệ false negative thấp và tỷ lệ false positive thấp. Hình 3 minh họa hai ranh giới quyết định của một SVM một lớp được xây dựng trên các điểm dữ liệu với hai đặc trưng. Trong hình, một ranh giới quyết định rộng được biểu thị bằng đường cong đứt nét, sẽ dẫn đến quá nhiều false negatives; trong khi ranh giới quyết định hẹp được biểu thị bằng đường cong liền nét, sẽ dẫn đến quá nhiều kết quả false positives.

Lấy kết quả của SVM một lớp làm đầu vào, giai đoạn thứ hai của cách tiếp cận được đề xuất của chúng tôi là tạo ra các mô hình hoạt động bất thường từ mô hình hoạt động bình thường. Các mô hình này được sử dụng để phát hiện bất thường.

B. Phát hiện hoạt động bất thường bằng lặp thích nghi trên mô hình đã huấn luyện

Chúng tôi tạo ra các mô hình cho các hoạt động bất thường trong một thủ tục lặp. Như thể hiện trong hình 3a, bắt đầu bằng cách chỉ có một mô hình chung cho các hoạt động bình thường. Với mô hình bình thường được ước tính tốt và một dấu vết kiểm tra, trước tiên chúng tôi tính toán khả năng theo dõi này được tạo ra bởi mô hình chung. Nếu khả năng (likelihood) nhỏ hơn ngưỡng được xác định trước θ , chúng tôi xác định dấu vết này là một ngoại lệ. Các ngoại lệ được coi là có thể đại diện cho một loại hình cụ thể của các hoạt động bất thường, do đó nó có thể được sử dụng để huấn luyện một mô hình hoạt động bất thường. Tuy nhiên, chỉ có một ngoại lệ duy nhất rõ ràng là không đủ để tạo ra một ước tính tốt về các tham số mô hình cho một mô hình hoạt động bất thường. Do đó, chúng tôi thực hiện phân tích hàm nhân phi tuyến hồi qui để điều chỉnh mô hình chung thành một mô hình hoạt động bất thường cụ thể bằng cách sử dụng ngoại lệ được phát hiện (xem hình 3b). Sau đó, khi một dấu vết kiểm tra khác đến, chúng tôi

tính toán khả năng tối đa tạo ra dấu vết này bởi các mô hình hiện có. Nếu khả năng tối đa được đưa ra bởi mô hình chung, chúng tôi dự đoán dấu vết này là một hoạt động bình thường; nếu không, chúng tôi xác định nó là bất thường. Trong trường hợp tiếp theo, chúng tôi phải quyết định liệu một mô hình hoạt động bất thường mới có được tạo ra hay không. Nếu khả năng tối đa cao hơn ngưỡng θ , chúng tôi coi dấu vết này thuộc về một mô hình bất thường hiện có; nếu không, dấu vết này được coi là một loại hoạt động bất thường mới. Vì vậy, chúng tôi lấy được một mô hình hoạt động bất thường mới từ mô hình bình thường chung (xem hình 3c).

Quy trình lập trong hình 3 như sau: Ban đầu, chỉ có một nút trong cây, đại diện cho mô hình bình thường chung. Khi phát hiện một hoạt động bất thường, một nút lá mới được tách ra từ nút cha trên, tạo ra một mô hình hoạt động bất thường. Khi một dấu vết bất thường khác được phát hiện, nếu nó có thể được đại diện bởi một trong những mô hình bất thường hiện có, cấu trúc cây vẫn giữ nguyên; nếu không, một mô hình hoạt động bất thường mới có nguồn gốc từ nút cha được hình thành. Cấu trúc cây này được sửa đổi một cách trực tuyến, cho phép tất cả các mô hình được tạo ra một cách hiệu quả. Trong trường hợp này, chúng tôi chọn điều chỉnh các vecto trung bình của mô hình. Để $\mu_i^{old}, 1 \leq i \leq Q$, biểu thị vecto trung bình của trạng thái thứ i . Sự thích nghi được thực hiện theo hai bước. Đầu tiên, với dữ liệu mới, ước tính mới của vecto trung bình μ_i^{new} được tính toán dựa trên mô hình chung. Thứ hai, vecto trung bình μ_i được điều chỉnh theo công thức sau:

$$\mu_i = \alpha \cdot \mu_i^{old} + (1 - \alpha) \cdot \mu_i^{new} \quad (14)$$

Ở đây α là yếu tố trọng số kiểm soát sự cân bằng giữa mô hình cũ và ước tính mới. Giá trị càng nhỏ, thì càng có nhiều đóng góp dữ liệu mới cho mô hình được điều chỉnh.

Để thực hiện các phép biến đổi tuyến tính giữa mô hình chung và dữ liệu thích ứng. Do đó, chúng tôi thực hiện sự thích nghi bằng cách sử dụng một hàm nhân phi tuyến hồi qui [31]. Ý tưởng cơ bản của hàm nhân phi tuyến hồi qui là ánh xạ các phép biến đổi hồi quy tuyến tính thành không gian đặc trưng chiều cao thông qua một bản đồ hạt nhân phi tuyến. Coi $A = [\mu_1^{old}, \dots, \mu_Q^{old}]$ và $B = [\mu_1^{new}, \dots, \mu_Q^{new}]$ biểu thị các vecto trung bình tương ứng với mô hình cũ và mô hình mới. Các vecto trung bình μ_i^* sử dụng hàm nhân phi tuyến hồi qui có thể được tính như sau:

$$\mu_i^* = (BK + \beta AK^{-1})(K^2 + \varepsilon I)^{-1} K \quad (15)$$

Trong công thức này, tương tự như α , β là một yếu tố trọng số cân bằng mô hình cũ và các ước tính mới. I là một ma trận nhận dạng và ε là thông số thường xuyên do người dùng xác định. Ma trận K là một hạt nhân ma trận $Q \times Q$:

$$K = \begin{bmatrix} k(\mu_1^{old}, \mu_1^{old}) & \dots & k(\mu_1^{old}, \mu_Q^{old}) \\ \vdots & \ddots & \vdots \\ k(\mu_Q^{old}, \mu_1^{old}) & \dots & k(\mu_Q^{old}, \mu_Q^{old}) \end{bmatrix} \quad (16)$$

Với $k(\dots)$ là hàm hạt nhân. Ở đây, để nắm bắt sự chuyển đổi phi tuyến giữa mô hình chung và dữ liệu thích nghi, chúng tôi cũng sử dụng hạt nhân RBF $k(\mu_i, \mu_j) = \exp(-\omega_2^2 \|\mu_i - \mu_j\|^2)$ để thích ứng với mô hình. Bằng việc tính toán (7), chúng tôi có thể có được một giải pháp tối ưu toàn cục cho các vecto trung bình cuối cùng μ_i^* , khi $1 \leq i \leq Q$.

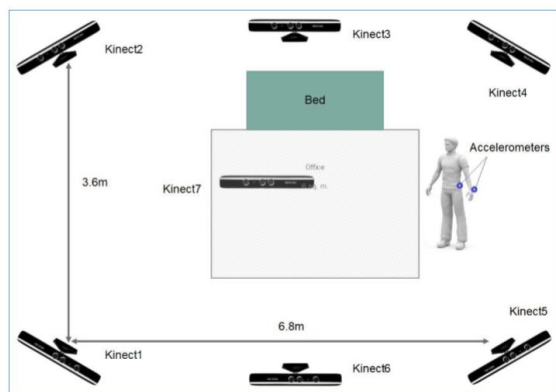
Sử dụng kỹ thuật thích ứng hàm nhân phi tuyến hồi qui ở trên cho phép phát hiện một hoạt động bất thường mới, từ mô hình hoạt động bình thường đã được huấn luyện.

IV. THỬ NGHIỆM VÀ ĐÁNH GIÁ

Phần này trình bày về thử nghiệm để đánh giá phương pháp phát hiện vận động bất thường đã trình bày ở trên.

A. Tập dữ liệu thử nghiệm

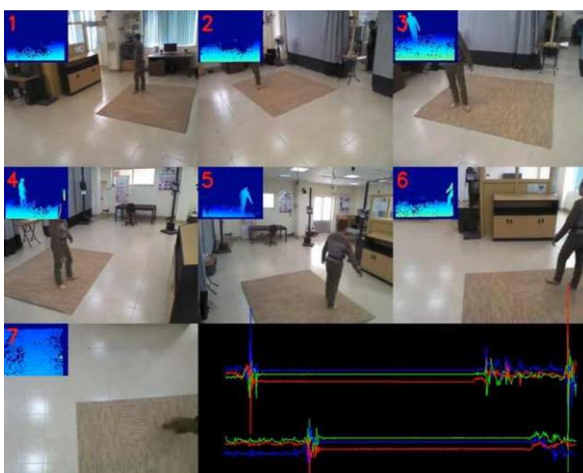
Thử nghiệm này sử dụng tập dữ liệu CMDFALL được thu thập bởi nhóm nghiên cứu về học máy và ứng dụng (Học viện Công nghệ Bưu chính Viễn thông (PTIT) kết hợp với nhóm nghiên cứu MICA tại đại học Bách khoa Hà nội [32]). Tập dữ liệu được thu thập từ 50 người, đeo 2 cảm biến gia tốc tại vùng thắt lưng và cổ tay và thực hiện 20 hoạt động và vận động bất thường (ở mức thấp với các nhãn được liệt kê như trong bảng 1). Môi trường thử nghiệm được thiết lập với 7 Kinect cameras tại các vị trí để thu nhận đầy đủ các góc nhìn ảnh (view) như hình 4 (môi trường thiết lập trong thử nghiệm).



Hình 4. Thiết lập môi trường thu thập dữ liệu

Mỗi người thực hiện 20 hoạt động với khoảng 7-8 phút nên tổng số thời lượng lên đến ~ 400 phút với hơn 350 Gigabyte dữ liệu. Dữ liệu thu thập được bao gồm cả ảnh RGB, Depth và Skeleton cùng với các file logging của dữ liệu cảm biến. Sau khi gán nhãn từ tập dữ liệu thu được tổng số lên tới 400 vận động bất thường và 600 hoạt động bình thường. Chi tiết về tập dữ liệu thử nghiệm có thể download tại website: <http://mica.edu.vn:8000/KinectData/Datasets>

Hình 5 là một khung hình được trực quan hóa từ tập dữ liệu; gồm 7 khung nhìn khác nhau từ 7 Kinect. Dữ liệu trực quan hóa bao gồm biểu đồ dữ liệu ảnh depth trên từng khung hình và dữ liệu cảm biến (góc dưới bên phải màn hình). Dữ liệu camera và cảm biến được đồng bộ nhờ một chương trình do nhóm nghiên cứu MICA-PTIT phát triển để đồng bộ nhờ vào các nhãn thời gian (timestamp).



Hình 5. Trực quan hóa dữ liệu ảnh chiều sâu (depth) và cảm biến

5.2. Kết quả

Bảng 2: Kết quả nhận dạng các hoạt động và phát hiện vận động bất thường trong tập dữ liệu CMDFALL.

Tên hoạt động	Độ chính xác (precision)	Độ nhạy (recall)
---------------	--------------------------	------------------

ngã về phía sau	75.43	76.23
bò trên mặt đất	56.31	62.22
ngã về phía trước	79.56	77.58
ngã về bên trái	77.63	79.14
lấy đồ bằng tay trái	58.41	57.32
nằm trên giường và ngã về bên trái	67.42	69.39
nằm trên giường và ngã về bên phải	65.43	64.57
nằm trên giường và ngồi lên xe lăn	68.22	65.44
di chuyển tay và chân	77.13	79.31
ngã về bên phải	71.36	76.25
lấy đồ bằng tay phải	91.78	93.42
chạy chậm	96.23	95.67
ngồi trên giường và đứng	87.23	88.41
ngồi trên ghế và ngã về bên trái	83.26	81.98
ngồi trên ghế và ngã về bên phải	84.12	83.67
ngồi trên ghế sau đó đứng dậy	89.61	91.34
nhảy loạn choạng	93.02	92.71
loạng choạng	84.25	82.59
đi bộ	94.46	95.58
hoạt động bất kỳ (chưa có nhãn)	53.12	58.47
Trung bình	76.32%	78.95%

Từ bảng trên chỉ ra rằng, hầu hết các hoạt động đều có kết quả có độ chính xác tương đối cao như đi bộ (walk) lên đến hơn 94% độ chính xác và độ nhạy; hay chạy chậm (run slowly) có độ chính xác và độ nhạy lên tới hơn 95%. Các hoạt động thường ngày khác như ngồi trên giường sau đó đứng lên, hoặc ngồi ghế rồi đứng lên có độ chính xác khá ổn định trong khoảng 87-90%. Ở chiều ngược lại, một số hoạt động như dùng tay trái lấy đồ vật có kết quả nhận dạng không tốt khoảng 50-60% độ chính xác. Điều này khá hợp lý do cảm biến được đeo bên phía tay phải mà không được đeo bên tay trái nên dữ liệu từ cảm biến thu thập được rất nhiều. Ngược lại các vận động bất thường như ngã theo các tư thế khác nhau (ngã bên phải, ngã bên trái, v.v..) có độ chính xác phát hiện không vượt

quá 80%. Đặc biệt hoạt động unknown là hoạt động không được gán nhãn chỉ có độ chính xác và độ bao phủ trên 50% vì đây là hoạt động chứa nhiều nhiễu nhất do nó được định nghĩa là tất cả các hoạt động mà không bao gồm các 19 hoạt động đầu tiên (có thứ tự từ 1-19) đã được định nghĩa trước. Độ chính xác và độ nhạy trong nhận dạng trung bình của cả 20 hoạt động và vận động bất thường là 76.32% và 78.95%.

V. KẾT LUẬN

Trong bài báo này, chúng tôi đã thực hiện một nghiên cứu về nhận dạng hoạt động bất thường, đề xuất sử dụng thuật toán EM để huấn luyện các mô hình học máy. Thực hiện một phương pháp nhận dạng hoạt động và phát hiện bất thường gồm hai giai đoạn, trong giai đoạn đầu tiên, SVM một lớp được thiết lập để lọc ra hầu hết các hoạt động bình thường; ở giai đoạn thứ 2, các dấu hiệu đáng ngờ được chuyển đến một tập hợp các mô hình hoạt động bất thường có điều chỉnh thông qua hàm nhân phi tuyến hồi qui để phát hiện thêm. Chúng tôi cũng đã tiến hành thực nghiệm và đánh giá kết quả của phương pháp đề xuất, với 20 hoạt động và vận động bất thường, độ chính xác và độ nhạy trung bình đạt được là 76.32% và 78.95%. Đây là kết quả rất đáng khích lệ cho các ứng dụng chăm sóc, hỗ trợ người cao tuổi. Vì vậy trong tương lai, chúng tôi sẽ tiếp tục mở rộng nghiên cứu theo hướng tập trung vào các phương pháp tự động trích chọn và biểu diễn các đặc trưng từ nhiều nguồn cảm biến để cải tiến độ chính xác phát hiện và nhận dạng, hoàn thiện ứng dụng gửi các trợ giúp cảnh báo về những vận động bất thường đến người chăm sóc nhằm hỗ trợ cuộc sống của người cao tuổi tại nhà bằng nền tảng kết nối internet vạn vật (IoT).

TÀI LIỆU THAM KHẢO

[1] Jindong, W., Yiqiang, C., Shuji, H., Xiaohui, P., Lisha, H.: Deep learning for sensor-based activity recognition: A survey. *Pattern Recognition Letters* 119: 3-11 (2019)

[2] Pham, C., Nguyen, N-D., Tu, M-P.; e-Shoes: Smart Shoes for Unobtrusive Human Activity Recognition. In *proc. of 9th IEEE International Conference on Knowledge Systems Engineering (IEEE KSE) 2017*. 269-274

[3] Nguyen, N., D. Pham, C., Tu, M., P.; Motion Primitive Forests for Human Activity Recognition Using Wearable Sensors. In *proc. of the 14th Pacific Rim International Conference on Artificial Intelligence (PRICAI) 2016*. 340-353

[4] Jie, J., Qiang, Y., Jeffrey, J. P.: Sensor-Based Abnormal Human-Activity Detection. *IEEE Trans. Knowl. Data Eng.* 20(8): 1082-1090 (2008)

[5] Tran, T-H., Le, T-L., Pham, D-T., Hoang, V-N., Khong, V-M., Tran, Q-T, Nguyen, T-S., Pham, C.; A Multimodal Multi-view Dataset for Human Fall Analysis and Preliminary Investigation on Modality. In the *proc. the 24th*

International Conference on Pattern Recognition (ICPR), 1947-1952. Beijing, China, 2018

[6] Y. Yao, F. Wang, J. Wang, and D.D. Zeng, "Rule based Exception Strategies for Security Information Analysis," *IEEE Intelligent Systems*, vol. 20, no. 5, pp. 52-57, Sept./Oct. 2005.

[7] P. Jarvis, T.F. Lunt, and K.L. Myers, "Identifying Terrorist Activity with AI Plan Recognition Technology," *Proc. 19th Nat'l Conf. Artificial Intelligence (AAAI '04)*, pp. 858-863, July 2004.

[8] J. Lester, T. Choudhury, N. Kern, G. Borriello, and B. Hannaford, "A Hybrid Discriminative/Generative Approach for Modeling Human Activities," *Proc. 19th Int'l Joint Conf. Artificial Intelligence (IJCAI '05)*, pp. 766-772, July-Aug. 2005.

[9] D.J. Patterson, L. Liao, L. Fox, and H. Kautz, "Inferring High-Level Behavior from Low-Level Sensors," *Proc. Fifth Int'l Conf. Ubiquitous Computing (UbiComp '03)*, pp. 73-89, Oct. 2003.

[10] Geoffrey McLachlan and Thriyambakam Krishnan. *The EM Algorithm and Extensions*. John Wiley & Sons, New York, 1996. [23] B. Scho'lkopf, J. Platt, J. Shawe-Taylor, and A. Smola, "Estimating the Support of a High-Dimensional Distribution," *Neural Computation*, vol. 13, no. 7, pp. 1443-1471, July 2001.

[11] L. Liao, D. Fox, and H. Kautz, "Learning and Inferring Transportation Routines," *Proc. 19th Nat'l Conf. Artificial Intelligence (AAAI '04)*, pp. 348-353, July 2004.

[12] J. Yin, X. Chai, and Q. Yang, "High-Level Goal Recognition in a Wireless LAN," *Proc. 19th Nat'l Conf. in Artificial Intelligence (AAAI '04)*, pp. 578-584, July 2004.

[13] P. Lukowicz, J. Ward, H. Junker, M. Sta'ger, G. Tro' ster, A. Atrash, and T. Starner, "Recognizing Workshop Activity Using Body Worn Microphones and Accelerometers," *Proc. Second Int'l Conf. Pervasive Computing (Pervasive '04)*, pp. 18-32, Apr. 2004.

[14] T. Xiang and S. Gong, "Video Behaviour Profiling and Abnormality Detection without Manual Labeling," *Proc. IEEE Int'l Conf. Computer Vision (ICCV '05)*, pp. 1238-1245, Oct. 2005.

[15] T. Duong, H. Bui, D. Phung, and S. Venkatesh, "Activity Recognition and Abnormality Detection with the Switching Hidden Semi-Markov Model," *Proc. IEEE Int'l Conf. Computer Vision and Pattern Recognition (CVPR '05)*, pp. 838-845, June 2005.

[16] S.D. Bay and M. Schwabacher, "Mining Distance-Based Outliers in Near Linear Time with Randomization and a Simple Pruning Rule," *Proc. Ninth ACM SIGKDD Int'l Conf. Knowledge Discovery and Data Mining (KDD '03)*, pp. 29-38, Aug. 2003.

[17] C. Elkan, "The Foundations of Cost-Sensitive Learning," *Proc. 17th Int'l Joint Conf. Artificial Intelligence (IJCAI '01)*, pp. 973-978, Aug. 2001.

[18] J. Ma and S. Perkins, "Time-Series Novelty Detection Using One-Class Support Vector Machines," *Proc. Int'l Joint Conf. Neural Networks (IJCNN '03)*, pp. 1741-1745, July 2003.

[19] M.M. Breunig, H.P. Kriegel, R. Ng, and J. Sander, "Identifying Density-Based Local Outliers," *Proc. ACM SIGMOD Int'l Conf. Management of Data (SIGMOD '00)*, pp. 93-104, May 2000.

[20] K.M. Ting, "A Comparative Study of Cost-Sensitive Boosting Algorithms," *Proc. 17th Int'l Conf. Machine Learning (ICML '00)*, pp. 983-990, June-July 2000.

[21] A.P. Bradley, "The Use of the Area under the ROC Curve in the Evaluation of Machine Learning Algorithms," *Pattern Recognition*, vol. 30, pp. 1145-1159, 1997.

[22] C.X. Ling, V.S. Sheng, and Q. Yang, "Test Strategies for Cost-Sensitive Decision Trees," *IEEE Trans.*

Knowledge and Data Eng., vol. 18, no. 8, pp. 1055-1067, Aug. 2006.

[23] Q. Yang, C. Ling, X. Chai, and R. Pan, "Test-Cost Sensitive Classification on Data with Missing Values," IEEE Trans. Knowledge and Data Eng., vol. 18, no. 5, pp. 626-638, May 2006.

[24] P. Domingos, "Metacost: A General Method for Making Classifiers Cost-Sensitive," Proc. Fifth Int'l Conf. Knowledge Discovery and Data Mining (KDD '99), pp. 155-164, Aug. 1999.

[25] U. Knoll, G. Nakhaeizadeh, and B. Tausend, "Cost-Sensitive Pruning of Decision Trees," Proc. 18th European Conf. Machine Learning (ECML '94), pp. 383-386, Apr. 1994.

[26] M. Kukar and I. Kononenko, "Cost-Sensitive Learning with Neural Networks," Proc. 13th European Conf. Artificial Intelligence (ECAI '98), pp. 445-449, Aug. 1998.

[27] G. Fumera and F. Roli, "Cost-Sensitive Learning in Support Vector Machines," Proc. Workshop Machine Learning, Methods and Applications, held in the Context of the Eighth Meeting of the Italian Assoc. Of Artificial Intelligence (AI*IA '02), Sept. 2002.

[28] P. Chan and S. Stolfo, "Toward Scalable Learning with Non-Uniform Class and Cost Distributions," Proc. Fourth Int'l Conf. Knowledge Discovery and Data Mining (KDD '98), pp. 164-168, Aug. 1998.

[29] Geoffrey McLachlan and Thiriyambakam Krishnan. The EM Algorithm and Extensions. John Wiley & Sons, New York, 1996. [23] B. Schoelkopf, J. Platt, J. Shawe-Taylor, and A. Smola, "Estimating the Support of a High-Dimensional Distribution," Neural Computation, vol. 13, no. 7, pp. 1443-1471, July 2001.

[30] B. Schoelkopf, J. Platt, J. Shawe-Taylor, and A. Smola, "Estimating the Support of a High-Dimensional Distribution," Neural Computation, vol. 13, no. 7, pp. 1443-1471, July 2001.

[31] I.W. Tsang, J.T. Kwok, B. Mak, K. Zhang, and J.J. Pan, "Fast Speaker Adaptation via Maximum Penalized Likelihood Kernel Regression," Proc. Int'l Conf. Acoustics, Speech and Signal Processing (ICASSP '06), May 2006.

[32] Pham, C., Nguyen, T.; Real-Time Traffic Activity Detection Using Mobile Devices. In proc. of the 10th ACM International Conference on Ubiquitous Information Management and Communications (ACM IMCOM) 2016. 641-647

[33] Pham, C.; MobiRAR: Real-Time Human Activity Recognition Using Mobile Devices. In proc. of the 7th IEEE International Conference on Knowledge Systems Engineering (IEEE KSE) 2015. 144-149

[34] Nguyen, N., D., Pham, C., Tu, M., P.; A Classifier Approach to Real-Time Fall Detection Using Low-Cost Wearable Sensors. In Proc. of the 5th International Symposium on Information and Communication Technology (SoICT) 2014. 14-20

[35] Pham, C.; MobiCough: Real-Time Cough Detection and Monitoring Using Low-Cost Mobile Devices. In proc. of the 8th Asean Conference on Intelligent Information and database systems (ACIIDS) 2016. 300-309

[36] Visalakshmi, S., Paul, E., Watson, P., Pham, C., Jackson, D., Olivier, P. 2011; Distributed Event Processing for Activity Recognition. In the Proceedings of the 5th ACM International Conference on Distributed Event-Based Systems (ACM DEBS) 2011 (New York, NY, 11-14 July 2011). 371-372

[37] Nguyen, L., Le, A., T., Pham, C.; The Internet-of-Things based Fall Detection Using Fusion Feature. Accepted at the 10th IEEE International Conference on Knowledge Systems Engineering (IEEE KSE) 2018. 129-134.

ABNORMAL HUMAN ACTIVITY RECOGNITION

USING NON-LINEAR KERNEL REGRESSION

Abstract: This paper proposes a 2-step method for human abnormal activity detection. In the first step, one hidden Markov model is trained for each normal activity, a support vector machine is used for classification of normal and abnormal activities; in the next step, abnormal data segments are inputted in a non-linear regression kernel for weight estimation for further detection. The models are trained using Expectation-Maximization (EM). An experiment on a dataset collected from 50 people with 20 normal and abnormal activities is conducted. The results of 76.32% precision and 78.95% recall have demonstrated the high potential of practical applications for health monitoring of the elderly and security.

Nhóm tác giả:



Nguyễn Tuấn Linh tốt nghiệp đại học ngành Công nghệ Thông tin, Đại học Giao thông Vận tải Hà Nội năm 2004. Nhận bằng Thạc Sĩ tại Đại học Thái Nguyên năm 2007.

Hiện tại là nghiên cứu sinh tiến sĩ tại Học viện Công nghệ Bưu chính Viễn Thông.

Lĩnh vực nghiên cứu: Kỹ thuật máy tính, điện toán tòa khắp, các mô hình học máy và công nghệ cảm biến cho các ứng dụng chăm sóc sức khỏe.

Email: nguyenlinhict@gmail.com



Vũ Văn Thỏa, nhận học vị Tiến sĩ năm 1990 tại Liên xô cũ.

Hiện công tác tại Học viện Công nghệ Bưu chính Viễn thông.

Lĩnh vực nghiên cứu: Lý thuyết thuật toán, tối ưu hoá, hệ thống tin địa lý, mạng viễn thông.

Email: thoa236@gmail.com



Phạm Văn Cường tốt nghiệp đại học năm 1998 ngành Công nghệ Thông tin, Đại học Quốc gia Hà nội; Nhận bằng Thạc sỹ năm 2005 tại ĐH bang New Mexico, Hoa Kỳ; Nhận bằng Tiến sỹ năm 2012 tại ĐH Newcastle Anh Quốc.

Hiện công tác tại Học viện Công nghệ Bưu chính Viễn Thông.

Lĩnh vực nghiên cứu: Học máy, điện toán tòa khắp, tương tác người máy, nhận dạng hoạt động của người, các thuật toán học máy và công nghệ cảm biến cho các ứng dụng chăm sóc sức khỏe, thị giác máy tính, các công nghệ cảm biến, hệ thống nhúng và điều khiển.

Email: pcuongcntt@gmail.com