



Tạp chí Khoa học Trường Đại học Cần Thơ

Phần A: Khoa học Tự nhiên, Công nghệ và Môi trường

website: sj.ctu.edu.vn



DOI:10.22144/ctu.jsi.2017.009

PHÁT HIỆN TÉ NGÃ CHO NGƯỜI CAO TUỔI BẰNG GIA TỐC KẾ VÀ MÔ HÌNH HỌC SÂU LONG SHORT-TERM MEMORY

Trần Công Án¹, Lữ Minh Phúc¹, Đỗ Thanh Đức¹, Ngô Bá Hùng¹, Lê Đình Chiên¹, Phạm Thị Xuân Diễm¹, Sơn Búp Pha² và Nguyễn Hữu Vân Long¹

¹Khoa Công nghệ Thông tin và Truyền thông, Trường Đại học Cần Thơ

²Phòng Tổ chức Cán bộ, Trường Đại học Cần Thơ

Thông tin chung:

Ngày nhận bài: 15/09/2017

Ngày nhận bài sửa: 10/10/2017

Ngày duyệt đăng: 20/10/2017

Title:

Elderly fall detection based on accelerometer and long short-term memory

Từ khóa:

Gia tốc kế, mạng neural hồi qui, người cao tuổi, phát hiện té ngã

Keywords:

Accelerometer, elderly, fall detection, ong Short-Term Memory

ABSTRACT

Fall is the most common cause of injury for elderly people. It does not only lead to physical injuries such as broken hip or head trauma, but also causes some psychological problems. However, early fall detection can help to reduce fall's consequences. Therefore, in this paper, an approach is proposed to detect elderly fall based on accelerometer data. The fall detection model is constructed using the long short-term memory deep learning architecture. A long short-term memory with 64 hidden units is used to train the detection model. The experimental result shows that this approach is suited to detect falls of the elderly with 93.9% of accuracy.

TÓM TẮT

Té ngã là một hiện tượng phổ biến của người cao tuổi. Té ngã không những gây ra các chấn thương sinh lý nghiêm trọng như gãy xương, tổn thương vùng đầu,... mà còn gây ra các tổn thương về tâm lý cho người cao tuổi. Ngoài việc phòng chống thì phát hiện té ngã một cách kịp thời có thể giúp hạn chế hậu quả của việc té ngã gây ra. Trong bài báo này, chúng tôi đề xuất một phương pháp phát hiện té ngã cho người già sử dụng gia tốc kế (accelerometer) trên các thiết bị di động. Mô hình nhận dạng té ngã được xây dựng dựa trên mô hình học sâu Long Short-Term Memory (LSTM). Chúng tôi sử dụng mô hình học sâu LSTM với 64 lớp ẩn. Kết quả thực nghiệm trên tập dữ liệu thực do chúng tôi thu thập thực tế cho thấy rằng mô hình đề xuất phù hợp cho việc phát hiện té ngã ở người cao tuổi với độ chính xác là 93,9%.

Trích dẫn: Trần Công Án, Lữ Minh Phúc, Đỗ Thanh Đức, Ngô Bá Hùng, Lê Đình Chiên, Phạm Thị Xuân Diễm, Sơn Búp Pha và Nguyễn Hữu Vân Long, 2017. Phát hiện té ngã cho người cao tuổi bằng gia tốc kế và mô hình học sâu Long Short-Term Memory. Tạp chí Khoa học Trường Đại học Cần Thơ. Số chuyên đề: Công nghệ thông tin: 65-71.

1 GIỚI THIỆU

Té ngã là một hiện tượng phổ biến của người cao tuổi. Theo thống kê của National Council on Aging (NCOA), cứ 4 người từ 65 tuổi trở lên thì có 1 người bị té ngã trong một năm. Một thống kê khác của Altman và các cộng sự cho thấy tỷ lệ người cao tuổi bị té ngã trong năm là khoảng 28% – 35% đối với

những người có tuổi từ 65 tuổi trở lên và 32% – 42% đối với những người có tuổi trên 75 (Altman et al., 2013). Hơn 15% trong số đó bị té ngã 2 lần trong năm.

Đối với người già, té ngã thường gây ra các tổn thương rất nghiêm trọng như gãy xương, tổn thương vùng đầu... Những số liệu gần đây của National

Center for Health Statistics cho thấy trong năm 2015, khoảng 55% của các ca tử vong do chấn thương của người cao tuổi tại Anh có nguyên nhân là do té ngã. Đối với những người có độ tuổi từ 75 trở lên thì tỷ lệ này là 78%. Điều này ảnh hưởng rất lớn đến kinh tế của gia đình, cộng đồng và cả xã hội (Kalache *et al.*, 2008).

Cũng theo nghiên cứu của Altman *et al.* (2013), té ngã không chỉ gây ra các chấn thương vật lý mà còn ảnh hưởng đến tâm lý của người cao tuổi. Nó làm cho người cao tuổi sợ việc vận động, qua đó tác động một cách gián tiếp đến sức khỏe của họ. Ngoài ra, khi điều trị chấn thương thường phải bị cách ly tạm thời ra khỏi cộng đồng, xã hội, làm tăng cảm giác cô đơn và có thể dẫn đến trầm cảm.

Việc phát hiện té ngã sớm có thể giúp người nhà, người chăm sóc (carer) hay bác sĩ đến một cách kịp thời và có thể giúp hạn chế hậu quả do té ngã gây ra (Bradley, 2011). Do đó, nhu cầu về các hệ thống phát hiện té ngã sớm và có khả năng thông báo cho người chăm sóc hay các người có liên quan là rất cấp thiết.

Trong bài báo này, chúng tôi đề xuất một phương pháp phát hiện té ngã cho người cao tuổi dựa trên gait kín thường được trang bị sẵn trên các thiết bị di động. Đây là một phương pháp phát hiện té ngã không quấy rầy (non-obtrusive), giúp cho người được quan sát không cảm thấy bị mất quyền riêng tư. Ngoài ra, phương pháp này cũng không bị giới hạn về mặt không gian như các phương pháp quấy rầy (obtrusive), thường dựa trên video, hình ảnh. Mô hình phát hiện té ngã được xây dựng dựa trên kiến trúc máy học sâu Long Short-Term Memory (LSTM). Đây là một kiến trúc học sâu có bộ nhớ, dựa trên kiến trúc học sâu mạng neural hồi quy (Recurrent Neural Network, RNN). Kiến trúc này phù hợp để học các dữ liệu dạng chuỗi thời gian (time-series) hay các dữ liệu có tính chất liên tục (sequence), phù hợp với vấn đề đang giải quyết.

Phần còn lại của bài báo được tổ chức như sau: Phần 2 sẽ tóm lược các nghiên cứu có liên quan; Phần 3 trình bày mô hình phát hiện té ngã bằng gait kín và kiến trúc học sâu LSTM; Phần 4 mô tả phương pháp thực nghiệm và các kết quả đạt được; ; kết luận về nghiên cứu sẽ được trình bày trong Phần 5.

2 CÁC NGHIÊN CỨU CÓ LIÊN QUAN

Các phương pháp phát hiện té ngã có thể được phân thành 2 loại chính: 1) phương pháp phát hiện té ngã có quấy rầy (obtrusive), và 2) phương pháp phát hiện té ngã không quấy rầy (non-obtrusive).

Các phương pháp phát hiện té ngã có quấy rầy thường dựa trên sự phân tích video hay hình ảnh.

Các nghiên cứu của Foroughi và các cộng sự phân tích sự biến đổi hình dạng của con người thu nhận được từ video để phát hiện té ngã (Foroughi *et al.*, 2008a; Foroughi *et al.*, 2008b; Foroughi *et al.*, 2008c). Trong nghiên cứu của Foroughi *et al.* (2008a), các hình ảnh thu được từ video sẽ được rút trích đặc trưng bao gồm phép toán xấp xỉ vừa nhất của đường biên xung quanh cơ thể người, biểu đồ ánh sáng của bóng người và sự thay đổi tư thế của đầu theo thời gian. Các đặc trưng này sẽ được sử dụng để phân lớp các hành vi dựa trên mô hình máy học vector hỗ trợ (SVM) để phát hiện té ngã. Phương pháp này có thể phát hiện được các hành vi té ngã với độ chính xác khoảng 88%. Cũng với các đặc trưng như trên nhưng trong một nghiên cứu khác, Foroughi *et al.* (2008b) sử dụng mạng neural nhân tạo (ANN) để phân lớp và phát hiện hành vi té ngã. Độ chính xác của phương pháp này cao hơn phương pháp sử dụng SVM với độ chính xác khoảng 91%. Ngoài các đặc trưng trên thì Foroughi *et al.* (2008c) còn sử dụng đặc trưng Integrated Time Motion Image (ITMI) và không gian Eigen kết hợp với SVM để xây dựng mô hình phát hiện té ngã. Phương pháp này có độ chính xác khoảng 89,5%.

Việc sử dụng video để phát hiện té ngã có ưu điểm là các video cung cấp nhiều thông tin để nhận dạng té ngã như hình dạng, vị trí và bóng của đối tượng được theo dõi, màu sắc, ánh sáng,... Tuy nhiên, phương pháp này có nhược điểm là ánh hưởng đến tính riêng tư của đối tượng được theo dõi và không gian bao phủ giới hạn. Do đó, phương pháp phát hiện té ngã không quấy rầy dựa trên các loại cảm biến như gait kín, con quay hồi chuyển đang được quan tâm nghiên cứu. Ưu điểm của phương pháp này là dữ liệu mà các sensor cung cấp chứa ít thông tin riêng tư của đối tượng được theo dõi.

Nghiên cứu của Li *et al.* (2009) đề xuất kết hợp con quay hồi chuyển và gait kín để phát hiện hành vi té ngã. Các tác giả sử dụng 2 mạch TEMP 3.0, mỗi mạch gồm 1 gait kín và 1 con quay hồi chuyển. Một mạch được gắn trên ngực của đối tượng cần được theo dõi và 1 mạch được gắn trên chân, đoạn giữa đầu gối và hông. Dữ liệu gait kín được sử dụng để xác định sự biến thiên của chuyển động còn con quay hồi chuyển thì dùng để tính độ quay của đối tượng. Các tác giả cũng đề xuất một số ứng dụng dựa trên sự quan sát các dữ liệu thu thập được để suy ra các tư thế của đối tượng như đứng, ngồi, nằm và gấp người lại. Các tác giả cũng đề xuất các luật để suy ra các hành vi như lên/xuống cầu thang, ngồi xuống một cách nhẹ nhàng, nhảy,... từ đó, suy ra các hành vi té ngã.

Cũng dựa vào gait kín, Chen và các cộng sự tại UC Berkely đã thiết kế một mạch phát hiện té

ngã sử dụng một cảm biến gia tốc kế MEMS, các vi xử lý và các chipset hỗ trợ truyền thông (Chen *et al.*, 2006). Thiết bị này sẽ được đeo vào vùng ngang thắt lưng của người được giám sát. Phương pháp phát hiện té ngã từ dữ liệu gia tốc kế trong nghiên cứu này dựa vào sự biến thiên của giá trị G-force:

$$g = \sqrt{x^2 + y^2 + z^2}$$

Nguồn của giá trị này được xác định một cách thủ công bằng cách phân tích các dữ liệu thực nghiệm. Tuy nhiên, mô hình này do chỉ sử dụng đặc trưng là giá trị G-force nên độ chính xác chưa cao, thường bị nhầm lẫn giữa các thao tác ngồi xuống và té.

Trong nghiên cứu của Brezme và các cộng sự, các tác giả sử dụng gia tốc kế trên điện thoại di động để nhận dạng các hành động đi, lên/ xuống cầu thang, đứng dậy, ngồi xuống và ngã (Brezme *et al.*, 2009). Mô hình nhận dạng các hoạt động được xây dựng bằng giải thuật k-láng giềng. Kết quả thực nghiệm được thông báo trong nghiên cứu trung bình cho tất cả các hành động là 80%. Tuy nhiên, quá trình thu thập dữ liệu, các đặc trưng dùng để học mô hình, cũng như quá trình kiểm tra tính chính xác của mô hình không được mô tả chi tiết. Đây là các thông tin rất quan trọng vì chúng ảnh hưởng rất lớn đến độ chính xác và độ tin cậy của mô hình.

Tuy không trực tiếp phát hiện té ngã nhưng các nghiên cứu về nhận dạng hành vi về bản chất cũng có liên quan rất lớn đến các nghiên cứu về phát hiện té ngã. Trong nghiên cứu của Bao và Intille, các tác giả đề xuất sử dụng 4 gia tốc 2 chiều gắn ở khuỷu tay, cổ tay, trên đầu gối và dưới cổ chân để phát hiện hơn 20 hành vi ADL (Bao and Intille, 2004). Các tác giả sử dụng phép biến đổi FFT với kích thước khung là 512 mẫu dữ liệu trên mỗi khung. Ngoài ra, một số đặc trưng khác cũng được sử dụng như thành phần DC (Direct Current) của FFT, mean, energy,... Các tác giả đã sử dụng 4 giải thuật để xây dựng mô hình phân loại bao gồm: cây quyết định, IBL, C45 và Naïve Bayes. Kết quả thực nghiệm cho thấy giải thuật C45 có độ chính xác trung bình cao nhất, khoảng 77%.

Cũng nghiên cứu về nhận dạng hành vi, Kwapisz và các cộng sự chỉ sử dụng 1 gia tốc kế để phát hiện các hành vi đi, nhảy, lên/xuống cầu thang, ngồi và đứng (Kwapisz *et al.*, 2011). Các tác giả sử dụng hơn 43 đặc trưng khác nhau, trong đó có 6 đặc trưng chính. Các đặc trưng này được phân lớp bởi giải thuật multilayer perceptron với độ chính xác khoảng 91,7%.

Trong một nghiên cứu gần đây về nhận dạng

hành vi dựa trên gia tốc kế của Ronao và Cho đã sử dụng giải thuật học sâu Convolutional Neural Networks để xây dựng mô hình nhận dạng (Ronao and Cho, 2016). Độ chính xác của nghiên cứu này khá cao, khoảng 94,7% với khả năng nhận dạng 7 hành vi đi, lên/xuống cầu thang, ngồi, đứng và nằm.

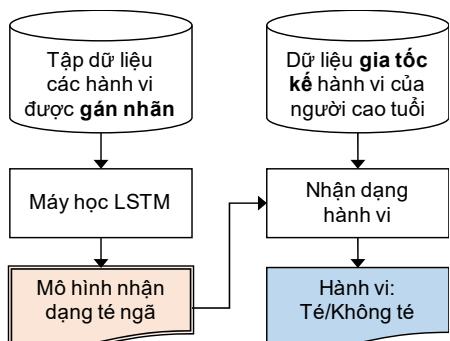
Một số nghiên cứu khác về nhận dạng hành vi như nghiên cứu của Maurer và các cộng sự sử dụng một đồng hồ đeo tay với 4 cảm biến, đạt được độ chính xác trung bình khoảng 75% cho 6 hành vi (Maurer *et al.*, 2006). Hay nghiên cứu của Lee và Cho sử dụng gia tốc kế trên các điện thoại di động cùng với HMM để phát hiện các hành vi đứng, đi, chạy và lên/ xuống cầu thang (Lee and Cho, 2011). Độ chính xác trong nghiên cứu này là nhất đối với hành vi chạy với khoảng 95%, còn các hành vi khác thì nằm trong khoảng 70% đến 80%.

Trong các nghiên cứu phát hiện té ngã có quấy rầy, đa số tác giả sử dụng cách tự phân tích dữ liệu để tìm ra quy luật phát hiện té ngã hoặc dùng mô hình máy học truyền thống như SVM, k-láng giềng. Đối với phương pháp tìm mô hình phát hiện bằng cách phân tích dữ liệu té ngã thì kết quả phụ thuộc rất nhiều vào chủ quan cũng như kinh nghiệm người phân tích. Còn đối với phương pháp dùng máy học truyền thống thì phụ thuộc vào việc lựa chọn đặc trưng. Việc lựa chọn đặc trưng cũng phụ thuộc nhiều vào kinh nghiệm của người xây dựng và cũng đòi hỏi việc phân tích dữ liệu để dự đoán, trích chọn đặc trưng phù hợp. Do đó, trong nghiên cứu này, chúng tôi muốn sử dụng kỹ thuật học sâu cho phép bỏ qua việc trích chọn đặc trưng. Ngoài ra, trong kỹ thuật học sâu có nhiều kiến trúc mạng neural phù hợp để học cho các dữ liệu có quan hệ về mặt thời gian như Recurrent Neural Network hoặc phiên bản mở rộng của nó là Long Short-Term Memory sẽ được sử dụng trong nghiên cứu này.

3 MÔ HÌNH PHÁT HIỆN TÉ NGÃ BẰNG GIA TỐC KẾ VÀ LSTM

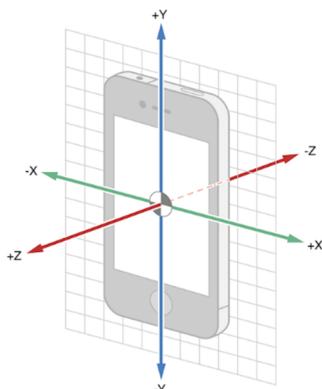
Trong nghiên cứu này, chúng tôi đề xuất một mô hình phát hiện hành vi té ngã ở người cao tuổi bằng gia tốc kế như được mô tả trong Hình 1.

Mô hình nhận dạng hành vi dựa trên giải thuật máy học sâu Long Short-Term Memory. Các dữ liệu gia tốc kế về các hoạt động của người cao tuổi sẽ được gán nhãn tương ứng với các hành động và được sử dụng để huấn luyện mô hình nhận dạng hành vi. Mô hình nhận dạng hành vi này sẽ được sử dụng để phát hiện té ngã trong các dữ liệu gia tốc kế về các hành vi của người cao tuổi. Chi tiết của các thành phần của mô hình này được mô tả như sau.

**Hình 1: Mô hình phát hiện té ngã bằng LSTM**

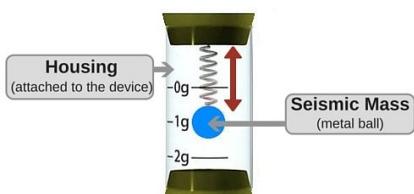
3.1 Gia tốc kế

Gia tốc kế là một thiết bị dùng để đo sự biến đổi gia tốc của đối tượng mang thiết bị. Các loại gia tốc kế thông dụng hiện tại đều có khả năng đo sự biến đổi gia tốc theo cả 3 chiều: x , y , và z . Hình 2 mô tả các chiều của một gia tốc kế trên các điện thoại di động thông minh (smartphone), trong đó x là trực hướng theo chiều ngang của thiết bị, y là trực hướng theo chiều thẳng đứng của thiết bị và z hướng từ sau ra trước.



Hình 2: Gia tốc kế 3 chiều trên smartphone
(Nguồn: <https://goo.gl/97bEFb>)

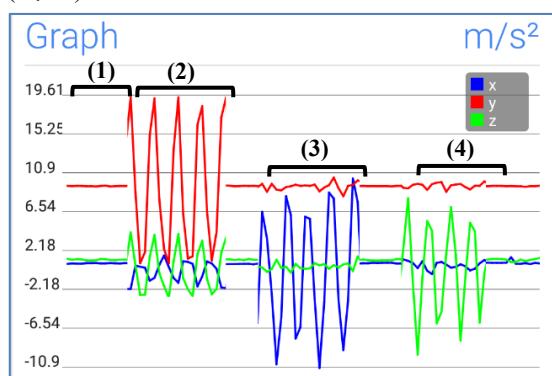
Đơn vị thông dụng được dùng để đo sự biến thiên của gia tốc là G hoặc m/s^2 . Hai đơn vị này có thể được chuyển đổi lẫn nhau bằng công thức: $1G = 9.8m/s^2$. Tùy từng loại gia tốc (độ nhạy) mà chúng có thể đo được sự biến đổi gia tốc cho mỗi chiều trong khoảng từ $[-1G, +1G]$ cho đến $[-3G, 3G]$. Nguyên lý để đo gia tốc theo trục y được mô tả trong Hình 3.



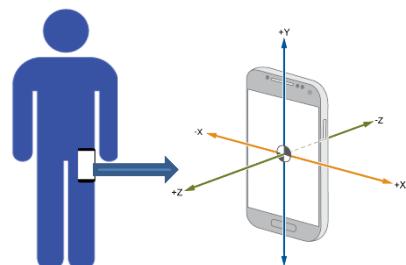
Hình 3: Nguyên lý đo gia tốc theo trục y
(Nguồn: <https://goo.gl/gB74Kj>)

Khi đặt gia tốc kế thẳng đứng theo trục y , do tác động của trọng lực thì khối lượng chuyển động (seismic mass) sẽ bị kéo xuống và giá trị chuẩn của trạng thái này là $+1G$. Khi di chuyển khoang chửa (housing) lên xuống theo phương thẳng đứng thì khối lượng chuyển động sẽ di chuyển, dẫn đến giá trị của y sẽ thay đổi. Độ biến thiên của y phụ thuộc vào việc gia tốc chuyển động của khoang chửa theo chiều thẳng đứng. Một gia tốc nhiều chiều sẽ bao gồm nhiều đơn vị đo gia tốc trong Hình 3, được đặt theo nhiều hướng khác nhau.

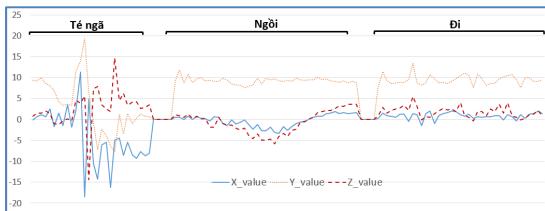
Hình 4 minh họa giá trị của x , y , z trong một số trường hợp khác nhau: (1) là trường hợp đặt gia tốc kế đứng yên theo phương thẳng đứng của trục y ; (2) là trường hợp di chuyển gia tốc kế lên xuống theo phương thẳng đứng (trục y); (3) là trường hợp di chuyển gia tốc kế qua lại theo chiều ngang (trục x); và (4) là trường hợp di chuyển gia tốc kế tới lui (trục z).

**Hình 4: Sự biến thiên giá trị x , y , z**

Trong nghiên cứu này, gia tốc kế sẽ được đặt trong túi quần của người cần được giám sát như được mô tả trong Hình 5 cùng với chiều của các trục x , y và z .

**Hình 5: Vị trí đặt gia tốc kế**

Hình 5 minh họa giá trị của x , y và z cho các hành vi té ngã, ngồi và đi. Qua các giá trị trong Hình 5 cho thấy việc phân biệt các hành vi dựa vào gia tốc kế là hoàn toàn khả thi.

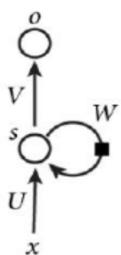


Hình 5: Các giá trị x, y, z tương ứng với các hành vi té ngã, ngồi, đi

Đối với thao tác té ngã thì sự biến thiên của x , y , và z là rõ rệt nhất. Đối với người cao tuổi thì các thao tác thường chậm rãi nên sự biến thiên của x , y và z khi ngồi xuống là khá ít. Đối với hành vi đi lại thì x và z ít biến động trong khi y là biến động rõ ràng nhất.

3.2 Xây dựng mô hình nhận dạng bằng mạng Long Short-Term Memory

Long Short-Term Memory (LSTM) là một kiến trúc học sâu được coi như là một sự mở rộng của Mạng neural hồi qui (Recurrent Neural Network, RNN) với khả năng học các phụ thuộc dài hạn (long-term dependencies) (Schmidhuber and Hochreiter, 1997; Mikolov *et al.*, 2014; Rojas, 2013). Đây là một mô hình mang có trí nhớ, có khả năng “nhớ” được các thông tin đã tính toán trước đó. Kết quả tại thời điểm hiện tại không những phụ thuộc vào đầu vào tại thời điểm hiện tại mà còn phụ thuộc vào kết quả tính toán của các thành phần ở những thời điểm trước. Do đó, kiến trúc mạng này được gọi là mạng “hồi qui” (recurrent).



Hình 6: Quá trình xử lý thông tin trong RNNs

Quá trình xử lý thông tin trong mạng hồi qui được mô tả trong Hình 6. Trong đó, x_t là input tại thời điểm thứ t , o_t là output tại thời điểm thứ t , S_t là trạng thái ẩn (hidden state) tại thời điểm thứ t , chính là “bộ nhớ” của mạng. S_t được tính dựa trên các trạng thái ẩn trước kết hợp với input tại thời điểm thứ t . Quá trình này có thể được biểu diễn bằng mô hình toán sau (Mikolov *et al.*, 2014):

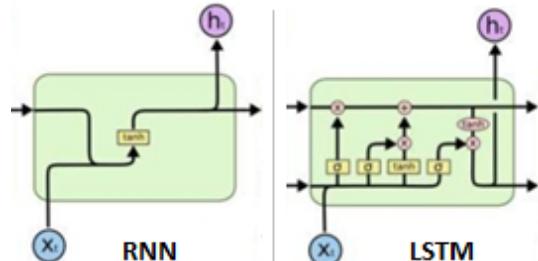
$$S_t = f(Ux_t + WS_{t-1})$$

với (U, V, W) là ba tham số của mạng.

Hàm f thường được sử dụng nhất là hàm tanh hoặc hàm RELU (Rojas Raúl, 2013).

Với khả năng “nhớ” được, đặc điểm chung của mạng neural hồi qui là có khả năng xử lý thông tin dạng chuỗi (sequential data) và các dữ liệu thời gian (temporal data).

Về lý thuyết, RNNs có thể nhớ được thông tin của chuỗi có chiều dài bất kỳ nhưng trong thực tế thì mô hình này chỉ có khả năng nhớ được thông tin ở một vài bước trước đó (Schmidhuber and Hochreiter, 1997). Do đó, để tăng khả năng nhớ thì bước xử lý lặp của LSTM sử dụng 4 lớp thay vì một lớp như RNN. Hình 7 mô tả sự khác nhau giữa cấu trúc 1 cell (module lặp) trong RNN và LSTM. Mấu chốt của khả năng “nhớ lâu” của LSTM là cấu trúc “trạng thái nhớ” (cell state), là đường kẻ ngang phía trên trong module lặp. Các thông tin có thể được thêm hoặc bớt vào cell state, dựa trên qui định của các cổng (gate), là các phép toán được đặt trong vòng tròn trong cell state.



Hình 7: Cấu trúc module lặp của RNN và LSTM

Trong nghiên cứu này, chúng tôi sử dụng kiến trúc học sâu LSTM với 64 lớp ẩn. Hàm mất mát (loss function) được sử dụng trong nghiên cứu này là hàm L2-norm (Least Squared Error, LSE). Hàm này cực tiểu hóa sự chênh lệch giữa giá trị mục tiêu y_i và giá trị dự đoán $f(x_i)$ theo công thức sau:

$$S = \sum_{i=1}^n (y_i - f(x_i))^2$$

Output tại thời điểm thứ t được tính dựa theo hàm softmax theo công thức sau:

$$O_t = \text{softmax}(VS_t)$$

Để tối ưu hóa mô hình, chúng tôi sử dụng thuật toán Adam Optimization (Kingma and Ba, 2014). Đây là sự mở rộng của thuật toán Stochastic Gradient Descent. Thuật toán này sử dụng 1 learning rate cho cả quá trình học và đường trung bình (moving average) của các dữ liệu gần nhất sẽ có trọng số cao hơn các dữ liệu đã xử lý xa hơn trước đó. Phương pháp này được gọi là đường trung bình siêu nhanh (exponential moving average), cho phép xử lý tốt hơn đối với các thay đổi gần nhất trong mô hình (Wu and Wei, 1989).

4 THỰC NGHIỆM

4.1 Tập dữ liệu thực nghiệm

Dữ liệu để huấn luyện và kiểm chứng mô hình được thu thập từ thực tế bằng cách gắn 1 điện thoại di động có cảm biến gia tốc kế vào túi quần của 1 tình nguyện viên. Trên thiết bị di động này có ứng dụng thu thập dữ liệu gia tốc kế hoạt động với tần số là 20Hz, nghĩa là trong 1 giây thì ứng dụng này sẽ thu thập được 20 tập giá trị (x , y , z). Tình nguyện viên này sẽ thực hiện mô phỏng các hành vi đi bộ, ngồi xuống, đứng lên. Các hành vi này sẽ được thực hiện dựa trên quan sát các hành vi của một người cao tuổi.

Ngoài ra, chúng tôi còn thu thập dữ liệu của hành vi té ngã bao gồm té ngã về trước, hai bên và ra sau. Dữ liệu té ngã được thu thập bằng 2 cách: 1) tình nguyện viên thực hiện thao tác té ngã nhẹ 2 bên trên nệm, 2) gắn thiết bị vào 1 mô hình người và cho ngã theo nhiều tư thế khác nhau, với nhiều mức độ khác nhau. Trong đó, dữ liệu thu thập theo cách 2 là nhiều hơn vì việc thực hiện thao tác té ngã bằng mô hình sẽ gần với thực tế hơn. Thông tin về tập dữ liệu thực nghiệm được cho trong Bảng 1.

Bảng 1: Thông tin về tập dữ liệu thực nghiệm

Hành động	Số lần thực hiện	Số điểm dữ liệu
Té ngã	50	8.256
Ngồi xuống	50	6.967
Đứng lên	50	7.298
Đi lại (25-30 giây/lần)	25	13.379
Tổng cộng		35.900

Trong huấn luyện và kiểm thử, các hành vi đi, đứng lên, ngồi xuống sẽ được gộp chung thành 1 lớp được gán nhãn là “không té ngã” (NOT FALL). Tập dữ liệu thực nghiệm này được chia thành 2 phần: 80% (28.720 mẫu) dùng để huấn luyện và 20% (7.180 mẫu) dùng để kiểm thử.

4.2 Môi trường thực nghiệm

Thực nghiệm (huấn luyện và kiểm thử) được tiến hành trên 1 máy tính với cấu hình như sau:

Thành phần	Cấu hình
CPU	Intel(R) Core(TM) i7-2600 CPU @ 3.40GHz
RAM	8GB
OS	Linux

Các thư viện và phần mềm hỗ trợ học sâu được sử dụng trong thực nghiệm là Miniconda, Tensorflow và PyCharm.

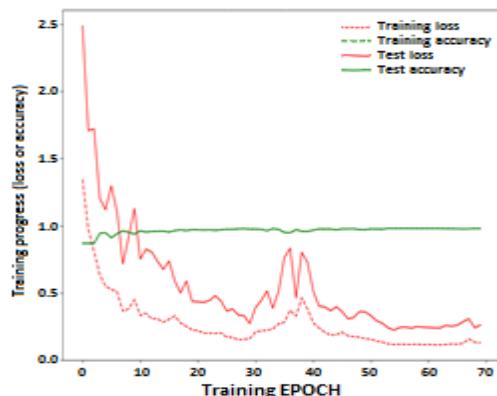
Một số thông số chính của mạng LTSM được sử dụng trong thực nghiệm để huấn luyện mô hình được cho trong Bảng 2.

Bảng 2: Thông số thực nghiệm

Thông số	Giá trị
Kích thước mỗi batch	200
Learning rate	0,025
Hidden layers	64
Feature	3
Số epochs tối đa	70
Activation function	RELU
Model optimization	Adam algorithm

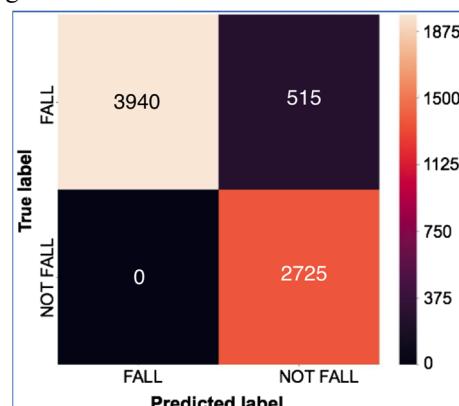
4.3 Kết quả thực nghiệm

Quá trình huấn luyện mô hình mất khoảng 30 phút với 70 lần lặp. Độ chính xác và độ lỗi trên tập huấn luyện và tập kiểm thử sau mỗi chu kỳ huấn luyện được cho trong Hình 8. Độ chính xác huấn luyện và kiểm thử tăng đều sau mỗi chu kỳ huấn luyện. Đến số chu kỳ huấn luyện 70 thì độ chính xác dần ổn định. Đối với độ lỗi trong huấn luyện và kiểm thử thì giảm mạnh trong 10 chu kỳ huấn luyện đầu tiên. Đến khoảng chu kỳ thứ 55 trở đi thì cũng bắt đầu ổn định.



Hình 8: Độ chính xác và độ lỗi qua từng epoch

Độ chính xác của mô hình thu được sau 70 chu kỳ lặp trên tập dữ liệu kiểm thử là 93,9%. Độ lỗi của mô hình này là 0,26. Chi tiết về độ chính xác trên tập kiểm thử được mô tả bằng ma trận nhầm lẫn trong Hình 9.



Hình 9 : Ma trận nhầm lẫn (confusion matrix)

5 KẾT LUẬN

Trong nghiên cứu này, chúng tôi đã đề xuất mô hình phát hiện té ngã cho người cao tuổi dựa vào dữ liệu gia tốc kế. Mô hình nhận dạng hành vi được xây dựng dựa trên mô hình Long Short-Term Memory của kỹ thuật học sâu với 64 lớp ẩn. Để kiểm thử mô hình, chúng tôi đã xây dựng một tập dữ liệu với các hành vi thông thường bao gồm đi lại, đứng lên, ngồi xuống và các hành vi té ngã với tổng số 36.994 điểm dữ liệu. Mô hình đề xuất đạt được độ chính xác 93,8% trên tập dữ liệu này. Độ chính xác này là tương đối tốt so với các nghiên cứu có liên quan và hoàn toàn có thể sử dụng cho các ứng dụng phát hiện té ngã thực tế để trợ giúp cho người cao tuổi.

Trong định hướng phát triển của đề tài, chúng tôi sẽ tiếp tục xây dựng một tập dữ liệu với nhiều hành vi hơn như lên xuống cầu thang, tập thể dục nhẹ tại chỗ,... Việc tăng số hành vi có thể cần phải thay đổi mô hình LSTM sao cho có thể học các mẫu hành vi phức tạp hơn như sử dụng nhiều LSTM chồng lên nhau hay thử với nhiều bộ thông số khác nhau của LSTM. Ngoài ra, hiện nay việc huấn luyện mô hình chỉ sử dụng dữ liệu thô x, y và z. Do đó, việc bổ sung thêm các đặc trưng thường được sử dụng trong nhận dạng hành vi như Fast Fourier Transform, độ lệch chuẩn, khoảng cách giữa các đỉnh dữ liệu,... có thể làm tăng độ chính xác của mô hình.

Cuối cùng, để có thể đánh giá được độ chính xác của mô hình một cách tốt hơn thì chúng tôi sẽ phát triển một ứng dụng cho các thiết bị di động sử dụng mô hình nhận dạng trong nghiên cứu này và cho thực nghiệm trực tiếp trên các người cao tuổi.

TÀI LIỆU THAM KHẢO

- Altman, I., Lawton, M. P., Wohlwill, J. F. (eds.), 2013. Elderly people and the environment. Vol. 7. Springer Science & Business Media.
- Bao, L., and Intille, S., 2004. Activity recognition from user-annotated acceleration data. *Pervasive computing*: 1-17.
- Bradley, S. M., 2011. Falls in older adults. *Mount Sinai Journal of Medicine: A Journal of Translational and Personalized Medicine* 78, no. 4: 590-595.
- Brezmes, T., Gorracho, J. L., and Cotrina, J., 2009. Activity recognition from accelerometer data on a mobile phone. *Distributed computing, artificial intelligence, bioinformatics, soft computing, and ambient assisted living*, pp. 796-799.
- Chen, J., Kwong, K., Chang, D., Luk, J., and Bajcsy, R., 2006. Wearable sensors for reliable fall detection. In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005*, pp. 3551-3554.
- Foroughi, H., Aski, B. S., and Pourreza, H., 2008a. Intelligent Video Surveillance for Monitoring Fall Detection of Elderly in Home Environments.
- IEEE 11th International Conference on Computer and Information Technology (ICCIT), pp. 24-27.
- Foroughi, H., Rezvanian, A., and Paziraei, A., 2008b. Robust Fall Detection Using Human Shape and Multi-Class Support Vector Machine. *IEEE 6th Indian Conference on Computer Vision, Graphics & Image Processing (ICVGIP)*, pp. 413-420.
- Foroughi, H., Yazdi, H. S., Pourreza, H., and Javidi, M., 2008c. An Eigenspace-based Approach for Human Fall Detection Using Integrated Time Motion Image and Multi-class Support Vector Machine. *IEEE 4th International Conference on Intelligent Computer Communication and Processing (ICCP)*, pp. 83-90.
- Kalache, A., Fu, D., and Yoshida, S., 2008. WHO Global Report on Falls Prevention in Older Age. World Health Organization Press, Geneva, Switzerland.
- Kingma, D., and Ba, J., 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv: 1412.6980*.
- Kwapisz, J. R., Weiss, G. M., and Moore, S. A., 2011. Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter* 12, no. 2: 74-82.
- Lee, Y. S., and Cho, S. B., 2011. Activity recognition using hierarchical hidden markov models on a smartphone with 3D accelerometer. In *International Conference on Hybrid Artificial Intelligence Systems*. Springer, Berlin, Heidelberg, pp. 460-467.
- Li, Q., Stankovic, J. A., Hanson, M. A., Barth, A. T., Lach, J., and Zhou, G., 2009. Accurate, fast fall detection using gyroscopes and accelerometer-derived posture information. In *Wearable and Implantable Body Sensor Networks, BSN 2009*, pp. 138-143.
- Maurer, U., Smailagic, A., Siewiorek, D. P., and Deisher, M., 2006. Activity recognition and monitoring using multiple sensors on different body positions. In *Wearable and Implantable Body Sensor Networks, 2006. BSN 2006*.
- Mikolov, T., Joulin, A., Chopra, S., Mathieu, M., and Ranzato, M. A., 2014. Learning longer memory in recurrent neural networks. *arXiv preprint arXiv:1412.7753*.
- Rojas, R., 2013. Neural networks: A systematic introduction. Springer Science & Business Media.
- Ronao, C. A., and Cho, S. B., 2016. Human activity recognition with smartphone sensors using deep learning neural networks. *Expert Systems with Applications* 59: 235-244.
- Schmidhuber, J., and Hochreiter, S., 1997. Long short-term memory. *Neural computation* 9, no. 8: 1735-1780.
- Wu, J. P., and Wei, S., 1989. Time series analysis. Hunan Science and Technology Press, ChangSha.
- Zhang, T., Wang, J., Xu, L., and Liu, P., 2006. Fall detection by wearable sensor and one-class SVM algorithm. *Intelligent computing in signal processing and pattern recognition*, pp. 858-863.