

ỨNG DỤNG MÁY HỌC VECTOR HỖ TRỢ SVM TRONG DỰ ĐOÁN CƠ ĐỘNG KINH

A METHOD BASED ON SVM TO PREDICT EPILEPTIC SEIZURES

Nguyễn Văn Sơn^{1*}, Vương Hoàng Nam², Đào Xuân Phúc¹, Vũ Duy Thuận³

¹Trường Đại học Mở Hà Nội, ²Trường Đại học Bách khoa Hà Nội, ³Trường Đại học Điện lực

Ngày nhận bài: 11/10/2019, Ngày chấp nhận đăng: 25/12/2019, Phản biện: TS. Nguyễn Hữu Phát

Tóm tắt:

Bệnh động kinh được xem là căn bệnh liên quan đến rối loạn trong não phổ biến thứ hai và ảnh hưởng đến khoảng 1% dân số thế giới. Đặc trưng của động kinh là sự xuất hiện bất chợt và mất kiểm soát của cơn co giật (cơn động kinh). Trong bài báo này, chúng tôi đề xuất một phương pháp sử dụng máy học vector hỗ trợ SVM (Support Vector Machine) để dự đoán cơn động kinh dựa trên các bản ghi tín hiệu điện não đồ EEG (Electroencephalography). Phương pháp này sử dụng các đặc trưng đơn biến của tín hiệu EEG nhằm phân loại bốn trạng thái tín hiệu EEG (bình thường, tiền động kinh, động kinh và sau động kinh). Việc dự đoán chính xác cơn động kinh phụ thuộc vào khả năng nhận dạng/phân biệt trạng thái tiền động kinh (pre-ictal) với ba trạng thái còn lại. Các kết quả mô phỏng với cơ sở dữ liệu động kinh của Đại học Freiburg cho thấy tính hữu dụng của phương pháp đề xuất.

Từ khóa:

Máy học vector hỗ trợ (SVM), dự đoán cơn động kinh, tín hiệu điện não đồ (EEG).

Abstract:

Epilepsy is the second most common brain disorder and affects approximately 1% of the world's population. Epilepsy is characterized by the occurrence of unforeseeable and uncontrollable seizures. In this paper, we propose a method based on SVM (Support Vector Machine) to predict epileptic seizures using EEG (Electroencephalography) recordings. In this method, univariate features are used to classify four states of EEG (inter-ictal, pre-ictal, ictal and post-ictal). Seizure forecasting requires the ability to reliably identify a pre-ictal state that can be differentiated from the inter-ictal, ictal, and post-ictal state. Computer simulation experiments with the Freiburg EEG database show the utility of the proposed method.

Keywords:

Torque constant; permanent magnet synchronous machine, state estimation, nonlinear observation, parameter identification.

1. GIỚI THIỆU

Động kinh là một bệnh mãn tính, do nhiều nguyên nhân khác nhau gây ra, đặc trưng là sự lặp đi lặp lại của các cơn do sự

phóng điện quá mức, đồng thời của các tế bào thần kinh não bộ, dù cho triệu chứng lâm sàng và cận lâm sàng có thể khác nhau. Các loại cơn động kinh được biểu

hiện vô cùng đa dạng hình thành nên “thế giới động kinh”. Ngày nay động kinh là một vấn đề quan trọng của ngành y tế và là bệnh lý mà xã hội và ngành y tế cần đặc biệt quan tâm vì những di chứng nặng nề của nó ảnh hưởng đến chất lượng cuộc sống, khả năng học tập công tác, hòa nhập cộng đồng và xã hội, đặc biệt là đối với trẻ em. Hiện nay việc điều trị bằng thuốc vẫn là lựa chọn hàng đầu, giúp hạn chế tác hại của động kinh đối với người bệnh. Tuy nhiên trong thực tế cuộc sống người bệnh động kinh vẫn chịu ảnh hưởng nặng nề bởi các cơn động kinh xuất hiện bất chợt, không dự đoán được.

Điện não đồ (EEG - Electroencephalogram) đo và biểu diễn sự thay đổi điện thế theo thời gian của các điện cực được đặt ở các vị trí khác nhau trên da đầu tương ứng với các vùng của vỏ não. Thông qua các đặc trưng biên độ, tần số, phân bố không gian, hình thái, sự phân cực của điện thế, EEG cho biết các thông tin về các hoạt động của não. Dựa trên các thông tin đó, các chuyên gia có thể đánh giá, phân tích các biểu hiện bất thường của bộ não để phát hiện bệnh động kinh dựa trên sự xuất hiện các gai động kinh trong EEG.

Các nghiên cứu gần đây trên thế giới tập trung theo hướng dự đoán và phát hiện sớm cơn động kinh (dựa trên tín hiệu EEG) với mục tiêu tạo ra các thiết bị gắn kèm với người bệnh có khả năng phát hiện cơn co giật trước khi cơn xảy ra. Điều đó sẽ giúp người bệnh (đặc biệt trẻ em) rất nhiều trong việc chủ động đối phó với bệnh động kinh [1,2].

Trong bài báo này chúng tôi đưa ra một phương pháp dự đoán trước cơn động

kinh sử dụng máy học vector hỗ trợ SVM (Support Vector Machine) và các đặc trưng được trích chọn từ tín hiệu EEG. Kết quả đánh giá phương pháp đề xuất được thực hiện trên bộ cơ sở dữ liệu về động kinh của Đại học Freiburg (CHLB Đức) [3].

2. MÔ HÌNH BÀI TOÁN DỰ ĐOÁN CƠN ĐỘNG KINH

Trong bài báo, chúng tôi chọn nghiên cứu bài toán phát hiện sớm (dự đoán) sự xuất hiện cơn động kinh của người bệnh. Trong trường hợp này đối tượng được nghiên cứu là bản ghi tín hiệu điện não đồ EEG đa kênh với các đặc trưng được lựa chọn bao gồm biên độ, tần số cơ bản, hình dạng và vị trí không gian ghi nhận trên da đầu (scalp)... và sẽ được phân loại dựa trên các đặc trưng được học của các mẫu học được lấy từ tín hiệu EEG của người bệnh. Mô hình bài toán đề xuất thực chất là một bài toán phân loại mẫu tín hiệu EEG gồm các bước:

- Thu thập dữ liệu;
- Tiền xử lý dữ liệu;
- Trích chọn các đặc trưng;
- Phân loại và hậu xử lý.

2.1. Thu thập dữ liệu

Trong các công trình khoa học nghiên cứu về nhận dạng, phát hiện bệnh lý động kinh chủ yếu sử dụng các bộ cơ sở dữ liệu (CSDL) chuẩn đã được đánh dấu (nhận dạng) bởi các chuyên gia y tế. Trong bài báo, chúng tôi đã sử dụng bộ CSDL của Đại học Freiburg là một trong rất ít bộ CSDL về động kinh được sử dụng phổ biến trong nghiên cứu hiện nay. Bộ dữ

liệu này gồm 18 bệnh nhân với tổng cộng 450 giờ ghi với 79 cơn động kinh [3].

2.2. Tiền xử lý tín hiệu


Quá trình này dùng để hạn chế và loại bỏ nhiễu trong tín hiệu điện não EEG. Chúng ta có ba cách: thứ nhất là ngăn chặn và loại bỏ các nguồn gây nhiễu; thứ hai là tối thiểu hóa ảnh hưởng của các nguồn nhiễu; thứ ba là nhận dạng và loại bỏ các tín hiệu nhiễu. Phương pháp tốt nhất để tín hiệu không có nhiễu là ngăn chặn và loại bỏ các nguồn gây nhiễu, tuy nhiên đối một số loại nhiễu (như nhiễu do nháy mắt, nhiễu cơ) thì phương pháp này không khả thi. Thứ hai ta có thể hạn chế tối đa nhiễu bằng việc sử dụng các thiết bị kỹ thuật đo đặc hiện đại có độ nhạy cao, khả năng lọc nhiễu tốt, tuy nhiên phương pháp này đắt tiền và phức tạp. Trong cách thứ ba, bằng việc sử dụng các thuật toán xử lý tín hiệu số chúng ta có thể khá dễ dàng nhận dạng các nguồn nhiễu và loại bỏ chúng. Phương pháp này không những không yêu cầu các thiết bị phần cứng phức tạp và đắt tiền mà còn có tính linh hoạt rất cao trong nhận dạng và loại bỏ nhiễu khỏi tín hiệu điện não. Tuy nhiên trong phạm vi nghiên cứu của bài báo, việc đánh giá kết quả dựa trên bộ CSDL chuẩn (đã được xử lý nhiễu) nên quá trình xử lý này được bỏ qua.

2.3. Trích chọn các đặc trưng

Mô hình cửa sổ trượt được sử dụng trong trích chọn đặc trưng của tín hiệu EEG (hình 1). Mỗi cửa sổ được xem như một mẫu tín hiệu cần nhận dạng. Cửa sổ trượt này có độ dài xác định trước trong đó các

đặc trưng về tín hiệu EEG sẽ được tính toán (phân tích) trong cửa sổ đó [1,2]. Độ dài của cửa sổ thường nằm trong khoảng 5÷40 giây. Sau phân tích cửa sổ trượt sẽ trả lại các giá trị phản ánh đặc trưng của các kênh khác nhau hoặc giữa các kênh của bản ghi EEG. Trong nghiên cứu này, khoảng thời gian cửa sổ được chọn là 5s. Khoảng thời gian cửa sổ trượt này phải nhằm thỏa mãn 2 điều kiện:

- Khoảng thời gian là đủ ngắn để quá trình xử lý được xem là tĩnh (stationary process).
- Khoảng thời gian là đủ dài để “bắt” (trích chọn) được các đặc trưng cụ thể của các mẫu tín hiệu EEG.



Hình 1. Phương pháp cửa sổ trượt để trích chọn các đặc trưng tín hiệu EEG


2.4. Phân loại và hậu xử lý

Trong bài toán phân loại này, chúng ta có thể phân làm 4 loại tín hiệu (hình 2) gồm: tín hiệu bình thường (ký hiệu là inter-ictal), tiền động kinh (pre-ictal), động kinh (ictal) và tín hiệu sau động kinh (post-ictal).

- Ictal: được xác định đoạn tín hiệu gắn hoạt động động kinh trong não. Hoạt động này có độ dài thay đổi nhưng thường kéo dài gần khoảng ba phút [4].
- Pre-ictal: được xác định là khoảng thời


gian ngay trước khởi phát cơn động kinh (seizure onset). Không có một định nghĩa y học cụ thể nào về giai đoạn này nhưng Mormann et al. 2007 [4] cho rằng đó là những sự thay đổi điện sinh lý học kéo dài nhiều phút đến hàng giờ trước cơn động kinh.

- Post-ictal: được xác định là khoảng thời gian (thường 5÷10 phút) hoạt động của não ngay sau kết thúc cơn (seizure offset) cho đến khi trở lại trạng thái bình thường [4].
- Inter-ictal: là đoạn tín hiệu không động kinh (bình thường), còn gọi là nằm trước trạng thái pre-ictal và nằm sau trạng thái post-ictal.



Hình 2. Phân loại trạng thái tín hiệu động kinh

Trong mô hình bài toán, đầu ra phân loại là giá trị nhãn gắn liền quan đến các vector đầu vào: chẳng hạn 1 đối với inter-ictal, 2 cho pre-ictal, 3 cho ictal và 4 cho post-ictal. Tuy nhiên điều chúng ta quan tâm nhất trong dự đoán động kinh là trạng thái tiền động kinh pre-ictal, do đó nhãn 2 trở thành nhãn quan trọng nhất. Quá trình hậu xử lý dựa trên cơ sở phát hiện khoảng thời gian tiền động kinh (pre-ictal), cho phép chúng ta đưa ra các cảnh báo sớm về cơn động kinh sắp xảy ra (hình 3).



Hình 3. Mô hình dự đoán đưa ra cảnh báo trước cơn động kinh

3. PHƯƠNG PHÁP ĐỀ XUẤT

Phương pháp đề xuất được xây dựng dựa trên mô hình bài toán dự đoán cơn động kinh đã được trình bày trong phần 2 với hai quá trình chính gồm: quá trình chọn đặc trưng tín hiệu EEG và quá trình phân loại và hậu xử lý.

3.1. Các đặc trưng tín hiệu EEG

Các đặc trưng này được sử dụng để phân loại 4 trạng thái tín hiệu: bình thường, tiền động kinh, động kinh và sau động kinh (inter-ictal, pre-ictal, ictal và post-ictal) từ bản ghi tín hiệu EEG của người bệnh động kinh. Trong thực tế các loại cơn động kinh biểu hiện rất đa dạng và bản thân tín hiệu điện EEG có sự biến thiên rất lớn (ngay cả đối với tín hiệu bình thường) về các đặc trưng cơ bản như tần số, biên độ, hình dạng và vị trí. Điều đó có nghĩa không tồn tại những đặc trưng có mối quan hệ định lượng chính xác với các trạng thái tín hiệu EEG hoặc cơn động kinh. Điều này dẫn đến trong dự đoán về động kinh ta phải sử dụng nhiều đặc trưng tín hiệu EEG.

Các đặc trưng này được chia làm hai loại: đặc trưng đơn biến (univariate) được lấy từ một kênh dữ liệu EEG [5] và đặc trưng lưỡng biến/đa biến (bivariate/multivariate) được tính toán dựa trên một cặp (hoặc nhiều hơn) kênh tín hiệu EEG [6]. Trong

bài báo, chúng tôi sử dụng 22 đặc trưng đơn biến của Jalil Rasekhi et al, 2013 [7] để phát hiện động kinh. Dữ liệu EEG trước tiên được phân đoạn theo từng cửa sổ 5s và các đặc trưng đơn biến lấy từ cửa sổ tín hiệu EEG sẽ thể hiện được các thông tin về cả biên độ lẫn pha/tần số của từng kênh tín hiệu EEG.

Câu hỏi đặt ra ở đây là liệu số lượng đặc trưng được chọn đã đủ để dùng dự đoán chính xác về cơn động kinh và việc lấy thêm đặc trưng khác (chẳng hạn các đặc trưng đa biến) liệu có làm tăng độ chính xác của dự đoán?

Thực tế việc sử dụng nhiều hơn số đặc trưng có thể làm tăng độ chính xác trong phân loại các trạng thái tín hiệu nhưng đồng thời dẫn đến một khối lượng tính toán vô cùng lớn. Điều đó có nghĩa chúng ta không thể thực hiện xử lý gần như tức thời (on-line) các tín hiệu EEG do độ trễ xử lý là rất lớn.

Ngoài ra để đưa ra các cảnh báo dự đoán về động kinh, chúng ta sử dụng thêm quá trình hậu xử lý (mục 3.2). Quá trình này sẽ đưa ra quyết định cuối cùng mà không cần một độ chính xác gần như tuyệt đối ở quá trình phân loại trạng thái tín hiệu.

3.2. Quá trình phân loại và hậu xử lý

Để xây dựng một hệ thống tự động phân biệt được các trạng thái của tín hiệu điện não đồ, chúng ta sử dụng máy học vector hỗ trợ SVM [8]. Bản chất SVM là phân loại nhị phân gồm 2 lớp (nhãn) đầu ra. SVM gốc chỉ thiết kế cho bài toán phân loại nhị phân, tuy nhiên trong nhiều ứng dụng thực tế thì buộc phải giải bài toán

phân loại nhiều lớp.

Vì vậy các mô hình SVM đa lớp cũng được nghiên cứu và phát triển để đáp ứng với các dạng bài toán phân loại nhiều lớp. Để phân loại 4 lớp đối tượng (trường hợp này) cần một tổ hợp SVM (SVM đa lớp).

Một số chiến lược thường dùng cho bài toán SVM đa lớp: Một đối một, một đối phần còn lại và chiến lược phân cấp. Trong trường hợp này, kỹ thuật một đối một (one-against-one) được sử dụng [9]. Kỹ thuật này được mô tả như sau:

Với mỗi cặp lớp phân loại, cần xây dựng một máy phân lớp nhị phân, mỗi máy phân lớp được huấn luyện trên một tập con của tập huấn luyện mà tập con này chỉ chứa các mẫu huấn luyện của cặp lớp phân loại này. Như vậy, phải xây dựng tất cả $k(k-1)/2$ máy phân lớp nhị phân với k là số lớp (trường hợp này với 4 lớp trạng thái tín hiệu chúng ta cần 6 máy học SVM), các máy này được kết nối lại với nhau và thông qua phương pháp bỏ phiếu để đánh giá kết quả phân lớp cuối cùng, lớp nào có số phiếu cao nhất sẽ được chọn làm kết quả dự đoán (max-win). Chiến lược này được sử dụng trong hầu hết các phần mềm mã nguồn mở như SVMlight, LIBSVM, SVMTorch và HeroSvm.

Trong đánh giá, đầu ra mạng SVM đa lớp là các nhãn (giá trị số) gán liên quan đến các vector đầu vào: 1 đối với inter-ictal, 2 cho pre-ictal, 3 cho ictal và 4 cho post-ictal. Tuy nhiên điều chúng ta quan tâm nhất trong dự đoán động kinh là phát hiện trạng thái tiền động kinh pre-ictal để tạo cảnh báo sớm về cơn động kinh sắp xảy ra, do đó nhãn 2 trở thành nhãn quan trọng nhất.

Quá trình tạo ra cảnh báo được thực hiện sau phân loại. Các SVM phân loại được “huấn luyện” dựa trên các mẫu học (learning). Một cách lý tưởng, thì các bộ phân loại SVM này (đã được huấn luyện tốt) sẽ phân loại chính xác tất cả các mẫu trong bộ dữ liệu kiểm tra (test) và do đó sẽ tạo ra được các đầu ra chính xác. Tuy nhiên, trên thực tế, một hệ thống phân loại sẽ không thể phân loại chính xác tuyệt đối tất cả các mẫu. Do đó nếu các đầu ra này được sử dụng trực tiếp để dự đoán về cơn động kinh thì sẽ dẫn đến với các mẫu bị phân loại nhầm thành pre-ictal sẽ tạo ra cảnh báo sai về cơn động kinh.

Để nâng cao chất lượng dự đoán, Teixeira et al. (2012) đưa ra một thủ tục tạo cảnh báo [10]. Do sai số phân loại, nên việc xuất hiện một khoảng thời gian với chuỗi nhãn phân loại toàn nhãn 2 (pre-ictal) là điều ít khi xảy ra, tuy nhiên trong các chuỗi nhãn nếu chuỗi nào có tần suất nhãn 2 nhiều thì có thể xem là khoảng thời gian có dấu hiệu của trạng thái tiền động kinh.

Trong bài báo, chúng tôi đề xuất giải pháp nếu trong một khoảng thời gian nào đó của bản ghi tín hiệu EEG (được xem là khoảng thời gian tiền động kinh, trong phần mô phỏng chúng tôi chọn khoảng thời gian này là 30 phút), nếu số lượng phân loại là pre-ictal (nhãn 2) vượt quá 50% thì cảnh báo về khả năng sự xuất hiện của cơn động kinh ở thời điểm tương lai gần sẽ được đưa ra.


4. KẾT QUẢ MÔ PHỎNG

4.1. Các thông số mô phỏng

4.1.1. Chọn kênh tín hiệu EEG

Như đã giới thiệu trên trong 2.1, bộ

CSDL của ĐH Freiburg gồm 18 bệnh nhân với tổng số khoảng 450 giờ ghi và 79 cơn động kinh. Mỗi bản ghi gồm tín hiệu của 27 kênh điện cực (hệ thống 10-20) bao gồm: FT10, T10, TP10, F8, T4, T6, FP2, F4, C4, P4, O2, FPZ, FZ, CZ, PZ, OZ, FP1, F3, C3, P3, O1, F7, T3, T5, FT9, T9, TP9. Ngoài ra còn có 2 kênh dùng để ghi kèm dữ liệu tín hiệu điện tâm đồ ECG (Electrocardiogram) của người bệnh (hình 4).



Hình 4. Một phần bản ghi dữ liệu của một bệnh nhân trong CSDL Freiburg với 27 kênh tín hiệu EEG và 2 kênh tín hiệu ECG (trong đó các vị trí EEG_ON và EEG-OFF đánh dấu vị trí bắt đầu và kết thúc một cơn động kinh)

Trên thực tế, việc sử dụng tín hiệu ở tất cả các kênh (27 kênh) sẽ dẫn đến khối lượng tính toán cực lớn. Ngoài ra việc sử dụng nhiều kênh tín hiệu cũng đồng nghĩa với việc người bệnh phải gắn nhiều điện cực trên người (trong trường hợp sử dụng các thiết bị cảm tay phát hiện sớm động kinh). Điều này sẽ gây ra sự bất tiện cho các bệnh nhân. Do đó trong phần thực nghiệm, chúng tôi chỉ sử dụng tổ hợp gồm 6 kênh tín hiệu (để nghiên cứu) nhằm phát hiện sớm cơn động kinh. Sáu kênh tín

hiệu được chọn theo tiêu chí bao phủ không gian. Sáu kênh tín hiệu được chọn gồm: F7, FZ, F8, T5, PZ và T6 cho cái nhìn không quan tổng quan về trạng thái não bệnh nhân. Theo tiêu chuẩn hệ thống vị trí đặt điện cực 10-20 của quốc tế thì vị trí đo F7, FZ, F8, T5, PZ và T6 bao phủ các khu vực phía trước, giữa và vùng thái dương.

4.1.2. Chọn đặc trưng tín hiệu

Chúng ta sử dụng một cửa sổ trượt 5s để trích chọn đặc trưng cho 6 kênh tín hiệu EEG đã được chọn, mỗi cửa sổ 5s này được xem là một mẫu phân loại thuộc một trong 4 trạng thái (inter-ictal, pre-ictal, ictal, post-ictal).

Do sử dụng đặc trưng đơn biến gồm 22 đặc trưng (mục 3.1), mỗi mẫu cần phân loại (cửa sổ 5s của 6 kênh) sẽ có 132 giá trị đặc trưng. Như vậy đầu vào của mạng phân loại sẽ là các vector (mẫu) 132 chiều.

4.2. Kết quả mô phỏng và đánh giá

4.2.1. Bộ dữ liệu học và kiểm tra

Bộ CSDL EEG được chia làm hai phần: bộ dữ liệu học, còn gọi là huấn luyện (learning) và kiểm tra (testing). Bộ dữ liệu học gồm khoảng 250 giờ ghi và 48 cơn động kinh được sử dụng để tối ưu các thông số của hệ thống phân loại (SVM đa lớp) trong khi bộ dữ liệu kiểm tra (gồm khoảng 200 giờ ghi và 31 cơn động kinh còn lại, không được dùng trong quá trình học) được sử dụng để kiểm tra tính hiệu quả của bộ phân loại đã được thiết kế từ quá trình học.

4.2.2. Một số kết quả mô phỏng và thảo luận

Ở đây chúng ta tiến hành đánh giá dựa trên bộ dữ liệu EEG của sáu kênh tín hiệu (F7, FZ, F8, T5, PZ và T6) với khoảng thời gian pre-ictal được chọn là 30 phút trước cơn động kinh, post-ictal được chọn là 10 phút sau cơn động kinh.

Trường hợp nếu xác định được trạng thái tiền động kinh (pre-ictal) và cơn động kinh xuất hiện trong khoảng thời gian sau cảnh báo ta sẽ có một dự đoán dương tính thật TP (True Positive) còn nếu không xuất hiện cơn ta sẽ có một dự đoán dương tính giả FP (False Positive). Khi trạng thái tiền động kinh (pre-ictal) không được xác định nhưng có cơn động kinh xuất hiện ta sẽ có một dự đoán âm tính giả FN (False Negative). Trong trường hợp này TP được xem là cảnh báo đúng còn FP và FN là các cảnh báo sai.

Để đánh giá kết quả ta sử dụng khái niệm độ nhạy (SS-Sensitivity) và tỷ lệ đoán sai (FPR/h- False Prediction per hour)[11].

SS được định nghĩa là tỷ lệ giữa số cơn dự đoán được/tổng số cơn động kinh trong bản ghi của người bệnh. Trong khi FPR/h được định nghĩa:

$$FPRh^{-1} = \frac{\text{False Alarm}}{\text{Hours of Testing} - (\neq \text{seizures} \times \text{preictal time})} \quad (1)$$

là tỷ lệ giữa số cảnh báo sai/ lượng thời gian hữu dụng.

Trong đó cảnh báo sai xuất hiện trong trường hợp có FP và FN (có cảnh báo nhưng không có cơn động kinh và không có cảnh báo nhưng lại xuất hiện cơn động kinh). Để xác định lượng thời gian hữu


dùng chúng ta lấy tổng số thời gian bản ghi tín hiệu EEG của người bệnh trừ đi tổng số thời gian dùng tạo cảnh báo (bằng số cơn động kinh nhân với khoảng thời gian pre-ictal được chọn) [11].

Về mặt lý thuyết kết quả thu được sẽ tối ưu (tuyệt đối) nhất khi đạt giá trị $SS=100\%$ và $FPR/h=0$ và trên thực tế chúng ta mong muốn một kết quả thu được với giá trị SS cao và FPR/h thấp.

Kết quả (tốt nhất) đối với bộ dữ liệu học chúng ta thu được tỷ lệ phát hiện cơn động kinh là 39/48 cơn, đạt tỷ lệ 81,25 %. Dựa trên thông số đã học, chúng ta tiến hành thử nghiệm trên bộ dữ liệu test. Kết quả thu được tỷ lệ phát hiện cơn là 21/31 cơn, đạt tỷ lệ 67,74 %. Hình vẽ 5 thể hiện tỷ lệ phát hiện cơn động kinh của các bệnh nhân trong bộ CSDL của Đại học Freiburg với tỷ lệ trung bình (cả quá trình học và test) là 75,9%. Điều này cho thấy khả năng ứng dụng triển vọng của phương pháp đề xuất trong bài báo. Trong mô phỏng này, không có các cảnh báo sai dương tính giả FP-False Positive (có cảnh báo nhưng không xuất hiện cơn động kinh). Trong bộ dữ liệu kiểm tra, với 10 cơn không nhận diện được, chúng ta có số cảnh báo sai tương ứng với 10 dự đoán âm tính giả FN và tỷ lệ FPR/h (đối với dữ liệu kiểm tra) đạt được là 0,055. Việc không có cảnh báo sai dương tính giả FP và tỷ lệ FPR/h rất thấp cũng là một kết quả hạn chế của bài báo do số lượng bệnh nhân, số cơn và loại (vị trí ổ bệnh) động kinh trong CSDL được đánh giá chưa nhiều và đa dạng.

Mặc dù không có một tỷ lệ cụ thể chung về giá trị SS tối thiểu hay FPR cực đại

dùng để đánh giá đối với các thuật toán, Teixeira et al. 2014 [11] đã đưa ra tỷ lệ dự đoán chấp nhận được (để ứng dụng trong y tế) là phải dự đoán được (đúng) ít nhất 50% số cơn động kinh ($SS>50\%$) và tỷ lệ cảnh báo sai không quá 1 lần trong khoảng thời gian 6 giờ ($FPR/h<0,15$) đối với từng người bệnh. Trên thực tế, các nghiên cứu khoa học gần đây nhất chưa có công trình nào đạt được tỷ lệ dự đoán này (cho cả hai thông số đánh giá) khi đánh giá dựa trên một CSDL động kinh đủ lớn.



Hình 5. Tỷ lệ phát hiện cơn động kinh của từng bệnh nhân trong bộ CSDL Freiburg

Trong nghiên cứu gần đây của Teixeira et al. 2014 [11], một đánh giá (thuật toán sử dụng các đặc trưng đơn biến và SVM đa lớp) trên 278 bệnh nhân được đưa ra. CSDL này bao gồm các bản ghi thời gian dài (gồm các bản ghi trung bình khoảng 70, 78 và 94 giờ) với xấp xỉ 22.291 giờ ghi và tổng cộng 1.519 cơn động kinh ở rất nhiều vị trí ổ bệnh khác nhau (thái dương-temporal, phía trước-frontal, chính giữa-central, thùy chẩm-occipital và thùy đỉnh-parietal). Ưu điểm của tín hiệu EEG thời lượng dài và liên tục là chứa khoảng thời lượng dài đoạn tín hiệu bình thường (inter-ictal). Điều đó rất quan trọng, đặc biệt khi dùng để đánh giá chính xác về tỷ lệ các cảnh báo sai. Kết quả tối ưu nhất trong [11] thu được là 32% số người bệnh có kết quả dự đoán chấp nhận được

(SS>50% và FPR/h <0,15 cho từng người bệnh).

5. KẾT LUẬN

Bài báo đã đưa ra một phương pháp dự đoán trước cơn động kinh sử dụng máy học vector hỗ trợ SVM đa lớp và các đặc trưng đơn biến của 6 kênh tín hiệu EEG gồm F7, FZ, F8, T5, PZ và T6. Mặc dù việc mô phỏng mới chỉ được đánh giá trên một bộ CSDL động kinh bị giới hạn (chỉ

với 18 bệnh nhân) nhưng với kết quả cho phép dự đoán trước cơn động kinh với tỷ lệ chính xác cao SS=67,74% đã cho thấy khả năng triển vọng của phương pháp dự đoán sớm cơn động kinh được đề xuất trong bài báo.

LỜI CẢM ƠN

Các tác giả bài báo xin trân thành cảm ơn sự hỗ trợ kinh phí nghiên cứu khoa học của Bộ Giáo dục và Đào tạo thông qua đề tài cấp Bộ mã số B2017-MHN.01.

TÀI LIỆU THAM KHẢO

- [1] Yadollahpour A. and Jalilifar M. (2014) "Seizure Prediction Methods: A review of the Current Predicting Techniques," Biomedical & Pharmacology, vol.7(1), 153-162, 2014.
- [2] Teixeira C.A. et al., (2011) "EPILAB: A software package for studies on the prediction of epileptic seizures," Journal of Neuroscience Methods, vol. 200, no. 2, pp. 257-271, Jul. 2011.
- [3] <http://epilepsy.uni-freiburg.de/freiburg-seizure-prediction-project/eeg-database>.
- [4] Mormann F., Andrzejak R.G., Elger C.E., and Lehnertz K., (2007) "Seizure prediction: the long and winding road.," Brain: a journal of neurology, vol. 130, no. 2, pp. 314-33, Feb. 2007.
- [5] Direito, B.; Duarte, J.; Teixeira, C. A.; Schelter, B.; Le Van Q. M.; Schulze-Bonhage, A.; Sales, F.; Dourado, A.. (2011) "Feature selection in high dimensional EEG features spaces for epileptic seizure prediction", IFAC Proceedings Volumes (IFAC-PapersOnline) 18, PART 1: 6206 - 62.
- [6] Feldwisch-Drentrup H, Staniek M, Schulze-Bonhage A, Timmer J, Dickten H, Elger CE, Schelter B, Lehnertz K.(2011) "Identification of preseizure states in epilepsy: a data-driven approach for multichannel EEG recordings, " Front Comput Neurosci 2011;5(0).
- [7] Jalil Rasekhi, Mohammad Reza Karami Mollaei, Mojtaba Bandarabadi, Cesar A Teixeira, Antonio Dourado (2013)"Preprocessing effects of 22 linear univariate features on the performance of seizure prediction methods" Neurosci Methods 2013 Jul 6;217(1-2):9-16. Epub 2013 Dec 6.
- [8] Cortes C. and Vapnik V., (1995) "Support-vector networks," Machine Learning, vol. 20, no. 3, pp. 273-297, 1995.
- [9] Hsu, C.W., and C.-J. Lin, (2002) "A Comparison of Methods for Multi-Class Support Vector Machines" IEEE Trans. Neural Netw., 13, 415 - 425, 2002.
- [10] Teixeira C., Direito B., Bandarabadi M., Dourado A. (2012) "Output regularization of SVM seizure predictors: Kalman Filter versus the "Firing Power" method," Conf Proc IEEE Eng Med Biol Soc. 2012;2012:6530-3
- [11] Teixeira C., Direito B., Quyen L. V. Micheal, Dourado A. (2014), "Epileptic seizure predictor based on computational intelligence techniques: A comparative study with 278 patients" Computer methods and programs in biomedicine, May 2014.

Giới thiệu tác giả:



Tác giả Nguyễn Văn Sơn tốt nghiệp đại học chuyên ngành điện tử viễn thông, nhận bằng Thạc sĩ chuyên ngành kỹ thuật điện tử năm 2010 tại Trường Đại học Mở Hà Nội. Hiện nay tác giả là giảng viên của Khoa Công nghệ điện tử - thông tin, Trường Đại học Mở Hà Nội.

Lĩnh vực nghiên cứu: điện tử viễn thông, xử lý thông tin và tín hiệu.



Tác giả Vương Hoàng Nam tốt nghiệp đại học ngành điện tử viễn thông năm 2003, nhận bằng Thạc sĩ và bằng Tiến sĩ ngành kỹ thuật viễn thông năm 2006 và 2013 tại Trường Đại học Bách khoa Hà Nội. Hiện nay tác giả là giảng viên Bộ môn Hệ thống viễn thông, Viện Điện tử viễn thông, Trường Đại học Bách khoa Hà Nội.

Lĩnh vực nghiên cứu: điện tử viễn thông, xử lý thông tin và tín hiệu, AI trong tự động hóa



Tác giả Đào Xuân Phúc tốt nghiệp Trường Đại học Bách khoa Hà Nội ngành điện tử viễn thông, nhận bằng Thạc sĩ ngành kỹ thuật điện tử năm 2011 tại Trường Đại học Mở Hà Nội. Hiện nay tác giả là giảng viên Khoa Công nghệ điện tử - thông tin Trường Đại học Mở Hà Nội.

Lĩnh vực nghiên cứu: điện tử viễn thông, xử lý thông tin và tín hiệu.



Tác giả Vũ Duy Thuận tốt nghiệp đại học ngành đo lường và tin học công nghiệp, nhận bằng Thạc sĩ ngành tự động hóa tại Trường Đại học Bách khoa Hà Nội năm 2004 và 2008, nhận bằng Tiến sĩ ngành điều khiển và tự động hóa tại Viện Hàn lâm Khoa học và Công nghệ Việt Nam năm 2018. Hiện nay tác giả là giảng viên Trường Đại học Điện lực.

Lĩnh vực nghiên cứu: điều khiển và tự động hóa, lập trình điều khiển.

