

So sánh mô hình học sâu với các phương pháp học tự động khác để nhận dạng gai động kinh biểu hiện trên đối tượng bệnh nhân động kinh

Comparison of Deep Learning Model with other Automatic Learning Models for Recognizing Spikes Expressed from Epilepsy Patients

Lê Thanh Xuyên*, Nguyễn Đức Thuận

Trường Đại học Bách khoa Hà Nội – Số 1, Đại Cồ Việt, Hai Bà Trưng, Hà Nội, Việt Nam

Đến Tòa soạn: 10-02-2020; chấp nhận đăng: 25-9-2020

Tóm tắt

Trong chẩn đoán lâm sàng bệnh động kinh bằng dữ liệu điện não (EEG), khả năng tự động phát hiện và phân loại một cách chính xác các gai động kinh là hữu ích và rất có ý nghĩa về y học. Bài báo giới thiệu một cách tiếp cận mới để phát hiện tự động gai động kinh (spike epilepsy). Hiện nay phân loại gai động kinh đã được thực hiện dựa trên nhiều phương pháp kết hợp của các mô hình machine learning. Nghiên cứu này chỉ ra một mô hình kết hợp mới mà cụ thể lấy deep learning làm tập con của machine learning để thực hiện phân loại các gai động kinh dựa trên nguồn dữ liệu chuẩn đã có. Nghiên cứu cũng thực hiện mô hình thực nghiệm với nhiều các mô hình học sâu khác để đánh giá khả năng ứng dụng mô hình trong việc phát hiện gai động kinh. Kết quả thực nghiệm cho thấy mô hình xây dựng có độ chính xác cao (98,8%) so với các nghiên cứu khác.

Từ khóa: Mạng nơron tích chập (CNN), học sâu (deep learning), học máy (machine learning), gai động kinh, các dạng sóng nhọn, tín hiệu điện não đồ (EEG).

Abstract

In the clinical diagnosis of epilepsy using EEG data, the ability to automatically detect and correctly classify epilepsy spikes is helpful and significant for medicines. The article introduces a new approach for automatic detection of spike. Currently, epilepsy classification has been progressed based on many combined methods of machine learning models. This study investigates a new combined model that specifically takes deep learning as a subset of machine learning to perform the classification of epilepsy based on existing standard data sources. The study also implements experimental models in other deep learning models to evaluate the applicability of the model in detecting epilepsy spikes. Experimental results show that the proposed model has high accuracy (98.8%) compared to other studies.

Keywords: Convolutional Neural Network (CNN), deep learning, machine learning, spike epilepsy, pick, EEG Electroencephalogram (EEG)

1. Đặt vấn đề

Deep learning là một lĩnh vực con của học máy (Machine learning). Các phương pháp học máy truyền thống (decision tree, logistic regression, naive bayes, support vector machine,...) [1] làm việc tốt nhờ có sự thiết kế các đặc trưng, các thuộc tính đầu vào của con người (Feature extraction). Machine learning sẽ tối ưu các trọng số của thuật toán để được kết quả dự đoán cuối cùng tốt nhất. Các phương pháp học máy cơ bản được triển khai dựa trên sự mô tả dữ liệu bằng các thuộc tính mà máy tính có thể hiểu được, đòi hỏi người thiết kế phải có sự hiểu biết nhất định trong lĩnh vực của bài toán đó, sau đó các thuộc tính được đưa qua thuật toán học nhằm tối ưu các trọng số của mô hình. Trái ngược với các phương pháp học máy truyền thống, Deep learning nỗ lực học các biểu diễn tốt nhất,

tìm ra những đặc trưng tốt nhất của dữ liệu một cách tự động. Đầu vào cho các thuật toán deep learning có thể là dữ liệu thô. Lý do để deep learning trở nên vượt trội so với các phương pháp truyền thống là các thuộc tính được trích chọn một cách thủ công thường được xác định một cách rõ ràng. Việc học ra các thuộc tính được thực hiện dễ dàng và nhanh chóng hơn, linh hoạt hơn trong biểu diễn thông tin. Deep learning có thể học không giám sát (không cần dữ liệu có nhãn sẵn, từ chính dữ liệu thô) hoặc học có giám sát (với các nhãn đặc biệt như positive/negative). Một bộ não hoạt động tốt là nhờ vào các tín hiệu điện mà các tế bào thần kinh truyền cho nhau. Tuy nhiên ở bệnh nhân mắc chứng động kinh, các bộ phận của não có mức tín hiệu điện cao bất thường, làm gián đoạn chức năng thần kinh bình thường. Ứng dụng phương pháp học sâu trong xử lý tín hiệu sinh học để hiểu rõ hơn mối quan hệ giữa gai (spike) và cơn co giật (seizures) [2, 3]. Deep learning xứng đáng là một sáng tạo vượt bậc đầy tiềm năng của lĩnh vực trí tuệ nhân tạo, hứa


*Địa chỉ liên hệ: Tel: (+84) 983519599
Email: xuyen.lethanh@hust.edu.vn

hện sẽ làm thay đổi cách thức hoạt động trong ngành y tế (phân loại mẫu trong các xét nghiệm,..).

Mô hình học sâu đặc biệt là mạng nơ-ron tích chập CNNs là mô hình được sử dụng phổ biến trong công đồng học máy cho hiệu quả trong các bài toán phân loại hình ảnh [4], phân loại văn bản và gần đây đã có nhiều nghiên cứu sử dụng mạng nơ-ron tích chập trong lĩnh vực tín hiệu sinh học [5] như phân tích Protein Zacharaki [6], phân tích ảnh y khoa [7]. Ưu điểm của CNN là tận dụng được tính năng trích chọn đặc trưng của lớp tích chập và bộ phân lớp được huấn luyện đồng thời. Ý tưởng học cùng lúc đặc trưng và bộ phân lớp có thể hỗ trợ với nhau trong quá trình huấn luyện và quá trình phân lớp tìm ra các tham số phù hợp với các véc-tơ đặc trưng tìm được từ lớp tích chập và ngược lại lớp tích chập điều chỉnh các tham số của lớp tích chập để cho các véc-tơ đặc trưng thu được là tuyến tính phù hợp với bộ phân lớp của lớp cuối cùng.

Những gai và sóng nhọn thường gặp trong bản ghi EEG của bệnh nhân động kinh. Các gai là những sóng có nền (cạnh đáy) hẹp có biên độ tương đối cao tạo cho sóng có hình dạng cao và hẹp với 1 đỉnh nhọn. Sóng nhọn có đáy hơi rộng một chút so với các gai nhưng cũng giống hệt, là điểm có hoạt động nên xảy ra cơn kích phát (seizure activity) phóng điện, hoạt động điện đồng bộ các đuôi gai (dendrites) của tế bào thần kinh. Các tiêu chuẩn xác định phóng điện dạng động kinh: điện thế cao, hình thái với gai: thời gian xuất hiện nhỏ hơn 70ms, sóng nhọn: 70-200ms, nền (background) bất thường, vị trí và trạng thái không giống như sự chuyển biến sinh lý thông thường [8]. Hình thái của gai rất đa dạng và phức tạp phụ thuộc vào bệnh nhân khác nhau giữa các bản ghi. Dạng phức hợp gai sóng (spikes and wave) và gai đặc trưng nhất có biên độ cao, chúng có thể xuất hiện đồng bộ (synchronously) và cân đối hai bên trong các bệnh động kinh toàn thể hóa (generalized epilepsies) hoặc khu trú trong bệnh động kinh cục bộ. Không có một định nghĩa rõ ràng về gai, hình thái của gai động kinh đa dạng và phức tạp thay đổi theo bệnh nhân [9]. Nhóm nghiên cứu qua bước tiền xử lý đã đề xuất bộ dữ liệu như hình 1. Gai động kinh có hình dạng của một đỉnh tín hiệu, việc tìm tất cả các đỉnh của hệ thống rất quan trọng để tìm các gai động kinh một cách chính xác. Một giá trị mẫu được so sánh với 2 đỉnh gần nhất, nếu giá trị mẫu là lớn nhất được định nghĩa là đỉnh dương, giá trị mẫu nhỏ nhất là đỉnh âm. Sau khi chọn đỉnh các đỉnh nhỏ chắc chắn không phải là gai động kinh được loại bỏ dựa trên các chỉ số ngưỡng sau: khoảng cách giữa một cặp đỉnh liền kề nhỏ hơn, khoảng cách giữa cặp đỉnh liền kề trước và sau đó [10]. Bước xử lý đã giúp hệ thống nhận biết các cơn động kinh dễ dàng hơn trong một số lượng lớn các đỉnh phát sinh từ nhiễu không mong muốn như nhiễu EMG (với biên độ nhỏ) được loại bỏ. Một

số gai động kinh thực tế trong tập dữ liệu nghiên cứu được mô tả trong Hình 1:



Hình 1. Mô tả bộ dữ liệu gai động kinh của 3 bệnh nhân (đánh dấu chấm: phần đỉnh, giữa, đáy) được sử dụng trong nghiên cứu

Trong các công trình nghiên cứu trước, việc quan trọng không thể thiếu là lọc dữ liệu. Tín hiệu EEG gồm rất nhiều thành phần bên trong nó, phụ thuộc vào tình trạng sức khỏe của từng bệnh nhân, điển hình là các nhiễu artifacts bao gồm: ECG, EOG, EMG... làm sai lệch và khó phát hiện được gai động kinh như mong muốn. Vì thế, việc đầu tiên của họ là lọc nhiễu để loại bỏ artifacts. Trong nghiên cứu này, tác giả không cần bất kỳ một phương pháp lọc nào, chỉ dùng dữ liệu thô (raw) để tiến hành vào quá trình phân loại. Vì thế, có thể nói đây là một ưu điểm, và lợi thế hơn khi không cần phải tìm hiểu những đặc điểm, đặc tính của các loại nhiễu để tiến hành loại bỏ chúng. Điều này sẽ giúp cho hệ thống hoạt động một cách nhanh hơn.

Ứng dụng mô hình học sâu các công trình nghiên cứu từ trước đến nay chủ yếu chuyên sâu để phát hiện ra các cơn động kinh dựa vào các xung động kinh (epileptic seizures). Trong khi đó gai động kinh có thể xuất hiện trong bản ghi EEG lúc bệnh nhân tỉnh táo, các công trình nghiên cứu về gai động kinh còn rất ít. Năm 2016 Johansen và đồng nghiệp sử dụng kỹ thuật mới là mạng nơ-ron tích chập (CNN) để phát hiện các dạng gai động kinh, giá trị hiệu suất AUC đạt được của hệ thống là 0,947, tuy nhiên nghiên cứu này không đưa ra giá trị độ nhạy Sensitivity (SEN)

Trong bài viết này, tác giả đề xuất huấn luyện mô hình mạng tích chập CNN để nhận dạng gai động kinh và so sánh hiệu quả của CNN với các thuật toán khác.

2. So sánh các mô hình học sâu giải quyết bài toán tìm gai động kinh

Trong các công trình nghiên cứu trước tác giả đã so sánh các thuật toán học máy phổ biến để tìm ra phương pháp tốt nhất cho bài toán phát hiện gai động kinh. Bài báo này vẫn tiếp tục ý tưởng đó bằng cách

thêm phương pháp CNN với nhiều ưu điểm hơn để đánh giá và lựa chọn phương pháp tối ưu. Mở rộng đầu vào biểu diễn dưới dạng đơn kênh trong phương pháp DBN thành đa kênh dưới dạng ten-xơ [11, 12] trong CNN để tính toán các thông số phát hiện gai động kinh.

Mạng nơ-ron tích chập (CNNs) [13] là một mô hình học sâu có thể xây dựng được các hệ thống phân loại với độ chính xác cao. Ý tưởng của CNNs được lấy cảm hứng từ khả năng nhận biết thị giác của bộ não người. Để có thể nhận biết được các hình ảnh trong vỏ não người có hai loại tế bào là tế bào đơn giản và tế bào phức tạp [14]. Các tế bào đơn giản phản ứng với các mẫu hình dạng cơ bản ở các vùng kích thích thị giác và các tế bào phức tạp tổng hợp thông tin từ các tế bào đơn giản để xác định các mẫu hình dạng phức tạp hơn. Khả năng nhận biết các hình ảnh của não người là một hệ thống xử lý hình ảnh tự nhiên đủ mạnh và tự nhiên. CNNs được phát triển dựa trên ba ý tưởng chính: tính kết nối cục bộ (Local connectivity, compositionality), tính bất biến (Location invariance) và tính bất biến đối với quá trình chuyển đổi cục bộ (Invariance to local transition) [15]. CNNs là một dạng mạng nơ-ron chuyên dụng để xử lý các dữ liệu dạng lưới 1 chiều như dữ liệu âm thanh, dữ liệu MGE hoặc nhiều chiều như dữ liệu hình ảnh. Các lớp cơ bản trong một mạng CNN bao gồm: Lớp tích chập (Convolutional), Lớp kích hoạt phi tuyến ReLU (Rectified Linear Unit), Lớp lấy mẫu (Pooling) và Lớp kết nối đầy đủ (Fully-connected), được thay đổi về số lượng và cách sắp xếp để tạo ra các mô hình huấn luyện phù hợp cho từng bài toán.

Lớp tích chập (Convolution) Tích chập được sử dụng trong xử lý số tín hiệu theo nguyên lý biến đổi thông tin, có thể áp dụng kỹ thuật này vào xử lý ảnh và video số. Trong lớp tích chập sử dụng các bộ lọc có kích thước nhỏ hơn với ma trận đầu vào, áp lên một vùng của ma trận đầu vào và tiến hành tính tích chập giữa bộ lọc (filter) và giá trị của ma trận trong vùng cục bộ đó. Các filter sẽ dịch chuyển một bước trượt (Stride) chạy dọc theo ma trận đầu vào và quét toàn bộ ma trận. Trọng số của filter ban đầu sẽ được khởi tạo ngẫu nhiên và sẽ được học dần trong quá trình huấn luyện mô hình.

Lớp phi tuyến Relu (Rectified linear unit) Giả sử mạng CNNs có L lớp có lớp input là lớp thứ 0. Mạng sẽ có L ma trận trọng số w được ký hiệu là $W^l \in R^{d^{(l-1)} \times d^l}$, $l = 1, 2, \dots$ trong đó W^l là các kết nối từ lớp thứ $l-1$ đến lớp thứ l , phần tử w_{ij}^l thể hiện kết nối của nơ-ron thứ i của lớp $(l-1)$ đến nơ-ron thứ j của lớp l . Các bias thứ (l) được ký hiệu là $b^l \in R^{d^{(l)}}$. Để thực hiện phân lớp có kết quả tối ưu là quá trình đi tìm bộ

tham số w và b . Mỗi nơ-ron không phải lớp input được tính bằng công thức:

$$a_i^{(l)} = f(w_i^{(l)T} a^{(l-1)} + b_i^l) \quad (1)$$

f là một hàm kích hoạt phi tuyến được áp dụng cho một ma trận. Trong kiến trúc mạng CNNs thường sử dụng hàm kích hoạt $f(x) = \max(0, x)$ chuyển toàn bộ giá trị âm trong kết quả lấy từ lớp tích chập thành giá trị 0 để tạo tính phi tuyến cho mô hình gọi là Relu. Ngoài ra còn có nhiều hàm kích hoạt khác như sigmoid, tang nhưng hàm relu dễ cài đặt tính toán nhanh và hiệu quả [16].

Lớp lấy mẫu (Pooling) sử dụng một cửa sổ trượt quét qua toàn bộ ma trận dữ liệu theo một bước trượt cho trước để tiến hành lấy mẫu. Các phương thức lấy phổ biến trong lớp Pooling là MaxPooling (lấy giá trị lớn nhất), MinPooling (lấy giá trị nhỏ nhất) và AveragePooling (lấy giá trị trung bình). Công dụng của lớp Pooling dùng để giảm kích thước dữ liệu, các tầng trong CNNs chồng lên nhau có lớp Pooling ở cuối mỗi tầng giúp cho kích thước dữ liệu được co lại nhưng vẫn giữ được các đặc trưng để lấy mẫu. Giảm kích thước dữ liệu sẽ giảm số lượng tham số của mạng tăng tính hiệu quả và kiểm soát hiện tượng học vẹt (Overfitting).

Lớp kết nối đầy đủ (Fully connect layer) Lớp kết nối đầy đủ là một lớp giống như mạng nơ-ron truyền thẳng các giá trị được tính toán từ các lớp trước sẽ được liên kết đầy đủ vào trong nơ-ron của lớp tiếp theo. Tại lớp kết nối đầy đủ sẽ tiến hành phân lớp dữ liệu bằng cách kích hoạt hàm softmax để tính xác suất ở lớp đầu ra.

Mạng học sâu cho nhận dạng gai động kinh, mạng bắt đầu với 1 loạt các tế bào thần kinh tương ứng 28x28 pixel của ảnh đầu vào, 784 tế bào thần kinh, mỗi tế bào đại diện cho giá trị màu xám của điểm ảnh tương ứng, từ 0 (đôi với pixel đen) đến 1 (đôi với pixel trắng), tất cả 784 các tế bào thần kinh tạo nên lớp đầu tiên của mạng nơ-ron. Lớp cuối cùng, lớp này có 10 tế bào thần kinh, mỗi tế bào đại diện cho một số tương ứng từ (7-17), giá trị kích hoạt của các tế bào thần kinh là một số 0&1. Mô hình thực nghiệm với phương pháp học sâu phân loại gai động kinh (hình 1).

Mô hình phân loại đa lớp sử dụng hàm softmax [17], cần có một hàm sao cho mỗi giá trị đầu vào x , a_i thể hiện xác suất mà nó rơi vào phân lớp thứ i với điều kiện:

$$\sum_{k=2}^K P(k|x) = 1 \quad (2)$$

nếu $z_i = w^T x$ càng lớn thì xác suất rơi vào lớp thứ i càng cao, nghĩa là cần một hàm đồng biến. z có

thể nhận giá trị dương hoặc âm, để đảm bảo z dương và đồng biến ta cho $\exp(z^i) = e^{-z_i}$. Sử dụng nhiều hàm sigmoid cho bài toán phân loại đa lớp, như vậy:

$$\sum_{k=2}^K P(k|x) \neq 1 \quad (3)$$

ta muốn đầu ra của mạng như là xác suất để đầu ra là của một lớp, ta sử dụng một hàm kích hoạt sum-to-one: softmax

$$a_i = \frac{\exp(z_i)}{\sum_{j=1}^c \exp(z_j)} \quad \forall i = 1, 2 \dots C \quad (4)$$

Khi z_i quá lớn, việc tính $\exp(z_i)$ thường gặp hiện tượng tràn số. Ta có thể khắc phục như sau:

$$\begin{aligned} \frac{\exp(z_i)}{\sum_{j=1}^c \exp(z_j)} &= \frac{\exp(-c)\exp(z_i)}{\exp(-c)\sum_{j=1}^c \exp(z_j)} \\ &= \frac{\exp(z_i - c)}{\sum_{j=1}^c \exp(z_j - c)} \end{aligned} \quad (5)$$

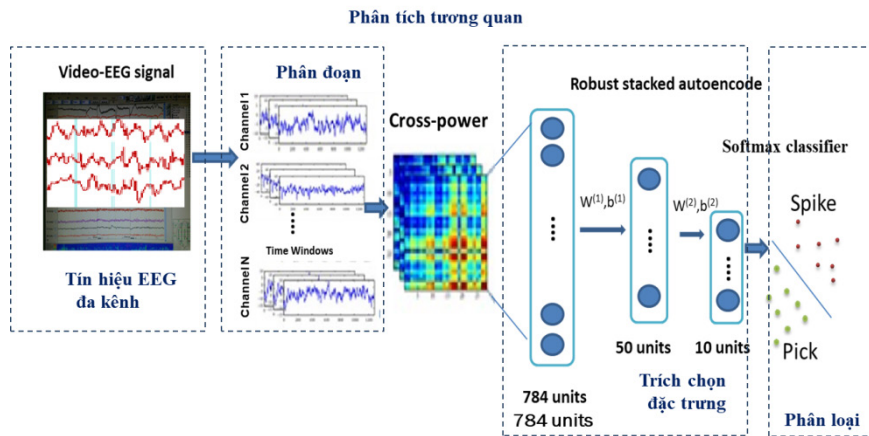
với c là một hằng số bất kỳ, thông thường $c = \max(z_i)$

3. Kết quả mô phỏng và đánh giá

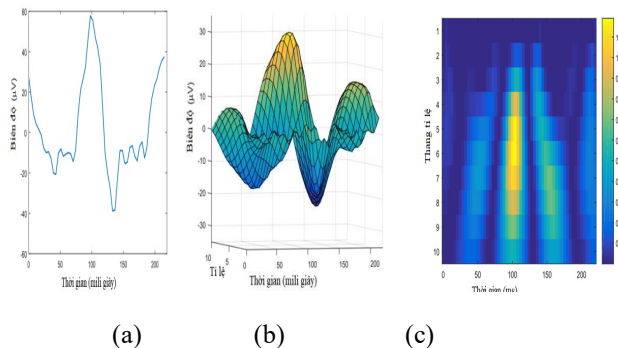
Mô hình thực nghiệm để đánh giá kết quả đưa ra CNN là tốt hơn các phương pháp trước DBN do đầu vào đã được đa kênh hóa và nhờ việc dùng các lớp Convolutional đưa ra kết quả chính xác hơn. Đề xuất giao thức mô hình Deep Learning cho phân loại gai động kinh trong các bản ghi điện não đồ (EEG) như hình 2.

Hình 3(a) gai động kinh biểu diễn gai động kinh theo thời gian. Hình 3(b) gai động kinh trong 10 thang tỉ lệ của phép biến đổi sóng con, 3D wavelet ở các scale từ 0 đến 10. Hình 3(c), năng lượng của mỗi hệ số biến đổi sóng con trong 10 thang tỉ lệ, biểu diễn giá trị hình ảnh.

Kết quả chạy thử nghiệm trên các mô hình đưa ra kết quả so sánh hiệu suất giữa CNN và các mô hình học máy khác như bảng 1. Kết quả cho thấy rằng SPE của CNN có độ chính xác cao nhất (98,89%).



Hình 2. Mô hình thực nghiệm với phương pháp học sâu phân loại gai động kinh



Hình 3. Minh họa các scale của biến đổi sóng con một gai động kinh trong 219ms (tương đương với 56 mẫu dữ liệu)

Bảng 1. Bảng so sánh hiệu suất model CNN và các model học khác

Model	SEN	SPE	AUC
CNN	88.45%	98.89%	0.9798
DBN	87.35%	97.89%	0.9597
ANN	65.74%	91.72%	0.8918
SVM	58.64%	92.53%	0.8815
kNN	28.40%	95.42%	0.8058

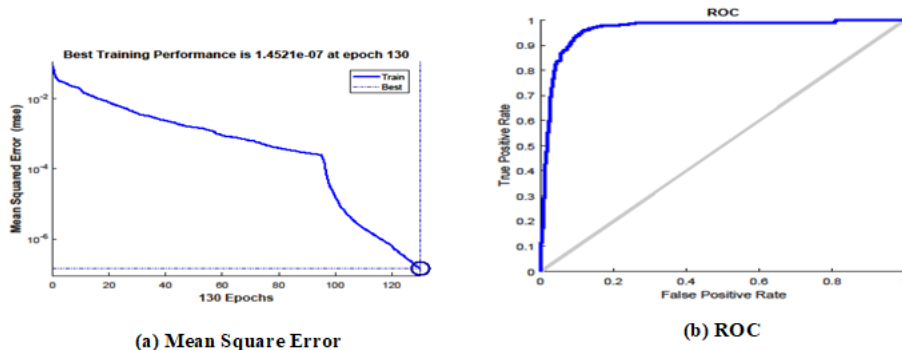
Bệnh động kinh khá nguy hiểm nhưng xác suất mắc bệnh của loại bệnh này đối với tỷ lệ dân số là rất thấp chẳng hạn 1:10000. Một người có các biểu hiện bệnh động kinh và thực hiện các xét nghiệm. Sau khi xem kết quả sẽ có giả định rằng bác sĩ kết luận sai. Khi đó có 2 khả năng xảy ra: Loại I: Bản thân bệnh nhân hoàn toàn bình thường, khi đo EEG bác sĩ kết luận bệnh nhân bị động kinh, Loại II: Bệnh nhân bị động kinh trong bản ghi EEG không có nhưng bác sĩ kết luận hoàn toàn bình thường. Rõ ràng sai lầm loại II gây ra hậu quả lớn hơn vì bệnh nhân không phát hiện sớm bệnh của mình để điều trị kịp thời sẽ dẫn đến bệnh phát triển xấu đi. Sai lầm loại I có ảnh hưởng tới chi phí khám chữa bệnh nhưng không ảnh hưởng đến sức khỏe và hậu quả là ít nghiêm trọng hơn. Một số phương pháp xử lý tín hiệu hỗ trợ nhận biết gai động kinh bằng kỹ thuật xử lý tín hiệu tiên tiến nhằm tăng tính khách quan và độ chính xác về mặt tín hiệu. Điều đó cho phép biết bệnh nhân có bị động kinh hay không, giảm tối thiểu tình trạng cảnh báo giả như loại II. Tác giả đã đưa ra tiềm năng mới của hệ thống học sâu, ứng dụng công nghệ mới cho bài toán nhận dạng gai động kinh xuất hiện trong các bản ghi EEG. Có nhiều tiêu chí được sử dụng để đánh giá hiệu suất của một hệ thống phân loại gai động kinh, các tham số đánh giá sau: Accuracy (ACC), Sensitivity (SEN), Specificity (SPE), Selectivity (SEL) được dùng một cách phổ biến đưa ra những

nhận xét khá tổng quan và chi tiết [4,15-117]. Sử dụng bộ tham số đánh giá này để kiểm tra chất lượng của hệ thống phân loại tín hiệu gai động kinh. Đánh giá một mô hình phân loại theo các tham số sau: tính toán độ nhạy (SEN), độ chọn lọc (SEL), độ đặc hiệu (SPE), hiệu suất của hệ thống (ACC) của CNN là tốt hơn. Các mô hình học máy đã được đánh giá chi tiết ở Bảng 1.

Độ nhạy, tính chọn lọc, tính đặc hiệu và độ chính xác, đó là biện pháp thống kê điển hình trong học máy và khoa học máy tính, được tác giả sử dụng để đánh giá chất lượng của hệ thống phát hiện gai động kinh. Qua hai hướng đánh giá trực quan và thống kê, cho thấy mạng CNN chuyển sang mô hình phân loại thực sự có khả năng tìm kiếm gai động kinh rất đáng mong đợi.

Ngoài ra, để trực quan hóa kết quả đánh giá, như hình 2.(a) (b) tác giả sử dụng đường cong ROC (Receiver Operating Curve) để mô tả chất lượng của hệ thống khi sử dụng các ngưỡng phân loại khác nhau, biểu đồ MSE (mean square error) cho biết tỉ lệ sai lệch. Kết quả phân loại tốt hơn khi hệ số MSE cho toàn bộ tập testing rất nhỏ khoảng 10^{-7} , trong khi đó đường ROC cũng cho thấy phần diện tích (AUC) dưới đường cong tiệm cận tới 1, hệ thống chỉ phải trả giá tỉ lệ dự đoán sai rất thấp khi muốn tăng tỉ lệ đoán đúng lên. Lấy ý tưởng từ bộ não sinh học, các mô hình học sâu xây dựng các thuật toán giúp máy suy nghĩ và xử lý thông tin giống như bộ não con người [18]. Nhờ có nhiều lớp thần kinh nhân tạo hơn học máy, học sâu sẽ có khả năng tự học và nhận diện nhiều vấn đề có cấp độ phức tạp hơn. Học sâu cho phép máy tính tự động hiểu, xử lý và học từ dữ liệu để thực thi nhiệm vụ được giao, cũng như cách đánh giá, giúp tăng tính hiệu quả [19].

Ứng dụng các thuật toán của phương pháp học sâu để giải quyết bài toán phát hiện và phân loại gai động kinh, đối tượng bệnh nhân là người Việt nam.



Hình 4. Đánh giá chất lượng hệ thống CNN

4. Kết luận

Trong bài báo này chúng tôi đã áp dụng mô hình học sâu để phân loại gai động kinh dùng thực nghiệm theo trình tự sau. Bước 1, xây dựng cơ sở dữ liệu (CSDL) cho các bản ghi EEG. Bước 2, tiền xử lý ảnh trong CSDL (lọc nền) và gán nhãn. Hai bước đầu tiên này chỉ cần thực hiện một lần khi xây dựng bộ CSDL ảnh huấn luyện cho phương pháp học máy truyền thống. Bước 3, thực hiện các bước tính toán cần thiết để ứng dụng mô hình CNN. Bước 4, huấn luyện mô hình nhận dạng gai động kinh từ CSDL ảnh đã xây dựng. Bước 5, thống kê độ chính xác, kết quả có thể thấy độ chính xác đạt được là rất cao ~98.8%, vượt trội so với độ chính xác của mô hình huấn luyện sử dụng phương pháp học máy truyền thống.

Các kết quả nghiên cứu từ thực nghiệm đã cho thấy tính hiệu quả của mô hình học sâu trong việc phát hiện gai động kinh.

Lời cảm ơn

Tác giả bài báo xin chân thành cảm ơn sự hỗ trợ khoa học từ nhóm nghiên cứu thuộc trường Đại học công nghệ Đại học quốc gia Hà Nội mã số CN.16.07. Giúp đỡ về ý tưởng khoa học của PGS.TS. Nguyễn Linh Trung. Bộ dữ liệu EEG dùng trong bài báo là một phần cơ sở dữ liệu động kinh EEG được xây dựng trong khuôn khổ dự án QG 10.40 do Việt nam tài trợ trường Đại học quốc gia Hà Nội.

Tài liệu tham khảo

- [1] C. D. A. Vanitha, D. Devaraj, and M. Venkatesulu, Gene expression data classification using support vector machine and mutual information-based gene selection, *Procedia Comput. Sci.*, vol. 47, pp. 13–21, 2015.
- [2] Chung JE, Magland JF, Barnett AH, Tolosa VM, Tooker AC, Lee KY, Shah KG, Felix SH, Frank LM, Greengard LF, A Fully Automated Approach to Spike Sorting, *Neuron* (2017).
- [3] Rossant C, Kadir SN, Goodman DFM, Schulman J, Hunter MLD, Saleem AB, Grosmark A, Belluscio M, Denfield GH, Ecker AS, Tolias AS, Solomon S, Buzsaki G, Carandini M, Harris KD. Spike sorting for large, dense electrode arrays, *Nature Neuroscience* (2016): 634-641.
- [4] Fakoor R, Ladhak F, Nazi A et al. Using deep learning to enhance cancer diagnosis and classification, *Proceedings of the International Conference on Machine Learning*. 2013.
- [5] Y. Kim, Convolutional neural networks for sentence classification, 2014.
- [6] E. I. Zacharaki, Prediction of protein function using a deep CNN ensemble, *PeerJ Prepr*, 2017.
- [7] S. Min, B. Lee, and S. Yoon, Deep learning in bioinformatics, *Brief. Bioinform*, 2016.
- [8] Stallkamp, Johannes, et al. The German Traffic Sign Recognition Benchmark: A multi-class classification competition. *Neural Networks (IJCNN)*, The 2011 International Joint Conference on Neural Networks. San Jose, CA, USA: IEEE, 2011.
- [9] Gotman, J. and Gloor, P. (1976), Automatic recognition and quantification of interictal epileptic activity in the human scalp EEG, *Electroenceph. Clin. Neurophysiol* 41, 513-529
- [10] Le Trung Thanh, Nguyen Thi Anh-Dao, Viet-Dung Nguyen, Nguyen Linh Trung, and Karim Abed-Meraim, Multi-channel EEG epileptic spike detection by a new method of tensor decomposition, *Journal of Neural Engineering* (major revise).
- [11] Martin Abadi et al., *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015.
- [12] Q. Li, W. Cai, et al., Medical image classification with convolutional neural network in *Control Automation Robotics & Vision (ICARCV)* 2014.
- [13] Y. LeCun, Y. Bengio, and G. Hinton, Deep learning *Nature*, vol. 521, no. 7553, pp. 436–444, 2015 Anal.
- [14] Stallkamp, Johannes, et al. The German Traffic Sign Recognition Benchmark: A multi-class classification competition, *Neural Networks (IJCNN)*, The 2011 International Joint Conference on Neural Networks. San Jose, CA, USA: IEEE, 2011.
- [15] Kelley DR, Snoek J, Rinn J. Basset: Learning the regulatory code of the accessible genome with deep convolutional neural networks. *bioRxiv* 2015:028399.
- [16] Le Thanh Xuyen et al. *VNU Journal of Science: Comp. Science & Com. Eng.*, Vol. 33, No. 2 (2017) 1-13
- [17] Ali Shoeb, Herman Edwards, Jack Connolly, Blaise Bourgeois, S. Ted Treves, John Gutttag. Patient-Specific Seizure Onset Detection. *Epilepsy and Behavior*. August 2004, 5(4): 483-498. [doi:10.1016/j.yebeh.2004.05.005]
- [18] E. I. Zacharaki, Prediction of protein function using a deep CNN ensemble *PeerJ Prepr*, 2017.
- [19] Y. Kim, Convolutional neural networks for sentence classification, 2014.