

ỨNG DỤNG MẠNG NƠ-RON XUNG VỚI KIẾN TRÚC TRUYỀN THẮNG CHO NHẬN DẠNG BỆNH ĐỘNG KINH

APPLICATION OF SPIKING NEURAL NETWORKS (SNNs) WITH FEEDFORWARD ARCHITECTURE FOR EPILEPSY DETECTION

Vũ Văn Thanh*, Phan Trần Đăng Khoa, Huỳnh Thanh Tùng, Trần Văn Líc

Trường Đại học Bách khoa - Đại học Đà Nẵng, Việt Nam¹

*Tác giả liên hệ / Corresponding author: vvthanh@dut.udn.vn

(Nhận bài / Received: 05/10/2024; Sửa bài / Revised: 24/11/2024; Chấp nhận đăng / Accepted: 25/11/2024)

Tóm tắt - Bệnh động kinh là một trong những rối loạn thần kinh phổ biến nhất, ảnh hưởng đến hàng triệu người trên thế giới. Phương pháp truyền thống trong phát hiện và dự đoán cơn động kinh thường dựa vào phân tích tín hiệu điện não đồ (Electroencephalogram Signals - EEG) qua các thuật toán máy học. Bài báo này đề xuất sử dụng mạng nơ-ron xung (Spiking Neural Networks-SNNs) với kiến trúc mạng truyền thẳng (feedforward) như một giải pháp mới nhằm nâng cao độ chính xác và tốc độ trong nhận dạng các cơn động kinh từ tín hiệu EEG. Kết quả thử nghiệm cho thấy, SNNs có khả năng nhận dạng chính xác cơn động kinh, đồng thời giảm độ phức tạp tính toán mà vẫn đảm bảo yêu cầu về độ chính xác. Tín hiệu điện não sau khi mã hóa thành chuỗi xung được đánh giá trên hai kiến trúc mạng khác nhau. Kết quả tốt nhất là độ trễ phát hiện 97 ms và độ chính xác 96,3% cho mạng feedforward lớn với 150 nơ-ron, với chỉ một số ít xung nằm ngoài sự kiện co giật.

Từ khóa - Mạng Nơ-ron Xung; kiến trúc Feedforward; nhận dạng bệnh động kinh; tín hiệu điện não đồ; học sâu.

1. Đặt vấn đề

Trong những năm gần đây, thông qua việc mô phỏng và tìm hiểu cách thức não bộ con người hoạt động, SNNs (spiking neural networks) đã được ứng dụng rất rộng rãi trong các mô hình và đã trở thành một mô hình tính toán mới với hiệu quả cao cho các ứng dụng của học máy, với các ưu điểm về việc có thể giúp giảm độ phức tạp tính toán mà vẫn đảm bảo yêu cầu về độ chính xác của ứng dụng. Tuy nhiên, thách thức chính của mạng SNNs là việc tìm ra một thuật toán huấn luyện hiệu quả cho SNNs, trong đó yêu cầu chiếm dụng ít bộ nhớ và có khả năng thực thi được trên các nền tảng phần cứng nhúng. Trong nghiên cứu [1] nhóm tác giả phòng Công nghệ mạng và Truyền thông, Viện Công nghệ Thông tin, Đại học quốc gia Hà Nội đã nghiên cứu đề xuất thuật toán huấn luyện ngoại tuyến với SNNs, với các trọng số của mạng được biểu diễn dưới dạng tam phân (được thể hiện với 2-bit). Thuật toán đề xuất giúp giảm yêu cầu bộ nhớ lên đến 16 lần so với việc lưu trữ các trọng số với độ chính xác dấu chấm động.

Trong lĩnh vực y sinh, bệnh động kinh được thống kê có thể ảnh hưởng sâu sắc đến hoạt động xã hội, tâm thần và cơ thể của bệnh nhân và sự ảnh hưởng này có thể nặng nề hơn bất cứ một tình trạng mạn tính nào [2, 3, 4]. Các nghiên cứu này có thể được xem là những công trình đầu tiên đánh giá ảnh hưởng của bệnh động kinh lên chất lượng

Abstract - Epilepsy is one of the most common neurological disorders, affecting millions of people worldwide. Traditional methods for detecting and predicting seizures often rely on analyzing electroencephalogram (EEG) signals through machine learning algorithms. This paper proposes using spiking neural networks (SNNs) with a feedforward architecture as a novel solution to enhance accuracy and speed in recognizing seizures from EEG signals. Experimental results indicate that, SNNs can accurately identify seizures while reducing computational complexity and maintaining accuracy requirements. The EEG signals, after being encoded into spike trains, were evaluated on two different network architectures. The best result achieved was a detection delay of 97 ms and an accuracy of 96.3% for a large feedforward network with 150 neurons, with only a few spikes occurring outside of seizure events.

Key words - Spiking Neural Networks; Feedforward architecture; epilepsy detection; electroencephalogram signals; deep learning.

cuộc sống của bệnh nhân. Các tác giả đã chỉ ra rằng, bệnh động kinh ảnh hưởng sâu sắc đến các khía cạnh xã hội, tâm lý và nghề nghiệp của bệnh nhân. Cụ thể, người bệnh thường phải đối mặt với sự kỳ thị xã hội, các vấn đề về tâm lý như trầm cảm và lo âu, cũng như các khó khăn trong cuộc sống hàng ngày, như mất việc làm hoặc không thể lái xe. Nghiên cứu cũng cho thấy sự kỳ thị xã hội có thể ngăn cản bệnh nhân tìm kiếm sự hỗ trợ y tế, làm trầm trọng thêm tình trạng bệnh.

Các nghiên cứu gần đây về SNNs ứng dụng trong lĩnh vực y sinh ngày càng được thu hút bởi chúng cung cấp một mô hình gần gũi hơn với hoạt động của não người khi so với các loại mạng nơ-ron truyền thống như MLP (Perceptron nhiều lớp) hay CNN (Mạng nơ-ron tích chập). Cụ thể, nghiên cứu trong [5] giới thiệu ứng dụng của SNN trong các hệ thống điều khiển cơ thể dựa trên giao diện não-máy tính (Brain-Machine Interface - BMI) nhằm giúp bệnh nhân phục hồi khả năng di chuyển hoặc kiểm soát các thiết bị ngoại vi thông qua các xung điện thần kinh từ não. SNN được sử dụng để giải mã các tín hiệu thần kinh phức tạp từ các cơ quan cảm giác, qua đó cho phép điều khiển chân tay giả một cách chính xác. Trong nghiên cứu [6], SNNs được áp dụng để phát hiện các cơn động kinh thông qua dữ liệu sóng điện não (EEG). Theo đó, mô hình SNNs có khả năng học, tổng hợp và phân tích thông tin từ các mẫu tín hiệu

¹ The University of Danang - University of Science and Technology, Vietnam (Van Thanh Vu, Tran Dang Khoa Phan, Thanh Tung Huynh, Van Lic Tran)

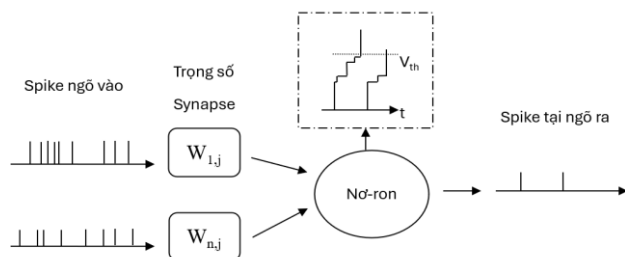
EEG phức tạp để nhận biết các cơn co giật. Nhờ khả năng xử lý theo thời gian thực và độ chính xác cao, SNN được chứng minh là phù hợp cho các ứng dụng phát hiện bệnh động kinh và theo dõi bệnh nhân. Nghiên cứu [7] tập trung vào việc sử dụng SNNs để điều khiển các thiết bị kích thích điện giúp phục hồi khả năng vận động cho bệnh nhân bị tổn thương tủy sống. Ngoài ra, SNNs có thể xử lý tín hiệu thần kinh phức tạp và tạo ra các xung kích thích để kích hoạt cơ bắp, giúp bệnh nhân khôi phục một số khả năng vận động. SNNs còn được sử dụng trong phát hiện các nhịp tim bất thường dựa trên tín hiệu điện tim (ECG) theo kết quả nghiên cứu trong [8]. Nhờ khả năng học và phân tích theo thời gian thực, SNNs có thể phát hiện các tình trạng nhịp tim không đều một cách chính xác, giúp hỗ trợ chẩn đoán các bệnh tim mạch và ngăn ngừa nguy cơ đột quỵ.

Vì vậy, nhóm tác giả thực hiện nghiên cứu này với mục tiêu sẽ khắc phục những khoảng trống trong nghiên cứu về SNN để phát triển được các mô hình học máy dựa trên kiến trúc SNN để thực hiện được các mục tiêu chẩn đoán và phát hiện bệnh sớm bệnh động kinh thông qua tín hiệu điện não để đảm bảo độ chính xác và nhanh chóng.

2. Mạng Nơ-ron Xung

SNNs là một loại mạng nơ-ron chịu ảnh hưởng từ cách hoạt động của các tế bào thần kinh sinh học. Khác với các ANNs truyền thống giao tiếp bằng các số thực liên tục, các nơ-ron trong SNNs truyền đạt thông tin thông qua các chuỗi xung phân tách [9]. Khi một nơ-ron tiền khớp thần kinh (synapse) phát đi một xung, nó ảnh hưởng đến điện thế màng của các nơ-ron sau synapse. Ở cấp độ synapse, các xung này được chuyển đổi thành các điện thế sau synapse (Post-synaptic potentials- PSP), làm thay đổi điện thế màng của nơ-ron nhận. Sự phát triển của điện thế màng của một nơ-ron được xác định bởi các PSP đến, và nếu điện thế này vượt qua ngưỡng cụ thể, nơ-ron sẽ phát ra một xung, sau đó được truyền đến các nơ-ron kết nối của nó [10].

Các hoạt động của một SNNs được minh họa trong Hình 1. Trong hình ảnh này, các chuỗi xung được đưa vào mạng và kết nối với một nơ-ron xung thông qua các synapse. Các trọng số synapse quy định mức điện thế của PSP, từ đó ảnh hưởng đến độ mạnh của kết nối giữa hai nơ-ron. Hình đi kèm cũng mô tả động lực của điện thế màng trong một nơ-ron xung, được thể hiện bởi mô hình nơ-ron đơn giản nhất được gọi là mô hình Tích lũy và Phát xung.




Hình 1. Sơ đồ của một nơ-ron đơn

Một trong những sự khác biệt chính giữa ANNs truyền thống và SNNs là cơ chế cập nhật. Trong các ANNs thông thường, tất cả các nơ-ron trong mỗi lớp đều được cập nhật trong mỗi chu kỳ tính toán, dẫn đến nhu cầu tính toán cao khi cấu trúc mạng mở rộng. Ngược lại, SNNs chỉ cập nhật

giá trị nơ-ron khi xảy ra xung, giúp chúng tiết kiệm tài nguyên tính toán hơn so với ANNs. Tính năng này cho phép SNNs thực hiện xử lý tín hiệu tiêu thụ điện năng thấp cho các tác vụ phức tạp, điều này đặc biệt hữu ích trong các ứng dụng như giám sát và phân loại theo thời gian thực.

Các xung đến được truyền qua các synapse, nơi các xung này được chuyển đổi thành các điện thế sau synapse (PSP) với trọng số. Trong hình, điện thế màng được hiển thị, và một xung được phát ra khi điện thế vượt quá ngưỡng V_{th} . Điện thế màng này được cập nhật dựa trên các PSP nhận được từ các synapse và mô hình nơ-ron (hàm kích hoạt).

Quy trình làm việc chung của mạng nơ-ron xung để nhận dạng bệnh động kinh được thể hiện qua Hình 2.




Hình 2. Quy trình làm việc của mạng nơ-ron xung để phân loại dữ liệu thời gian

Đầu tiên, dữ liệu đầu vào là các tín hiệu điện áp đo được từ các điện cực não, thường là các tín hiệu EEG ghi lại hoạt động điện của não qua các điện cực đặt trên da đầu. Dữ liệu được sử dụng trong bài báo này là các điện thế trường cục bộ (LFP- Local Field Potentials) được ghi lại từ các lát cắt của não, được thu thập trong dự án Châu Âu HERMES [11]. Mục tiêu của dự án này là chữa các rối loạn não như động kinh thông qua việc cấy ghép mô não. Đây là sự tích hợp của mô não được kỹ thuật sinh học, điện tử thần kinh và trí tuệ nhân tạo, có khả năng đọc và kích thích khu vực bị ảnh hưởng.

Tiếp theo, sử dụng phương pháp mã hóa tiếp bước (Step-Forward Encoding - SFE) để chuyển đổi tín hiệu liên tục này thành các xung điện [12]. Trong quá trình này, sự thay đổi điện áp trong một khoảng thời gian xác định sẽ được chuyển đổi thành các xung bằng cách so sánh mức độ thay đổi.

Sau đó, các xung điện này được đưa vào mạng SNNs với kiến trúc mạng là mạng truyền thẳng để nhận diện các mẫu xung liên quan đến động kinh. Kiến trúc mạng truyền thẳng trong SNNs bao gồm các lớp nơ-ron được kết nối theo một hướng từ đầu vào đến đầu ra mà không có vòng lặp. Điều này giúp cải thiện tính đơn giản và hiệu quả trong quá trình học.



Hình 3. Ví dụ về một mạng nơ-ron chuyển tiếp

Trong mạng nơ-ron chuyển tiếp (FeedForward), có ba thành phần chính: lớp đầu vào (input layer), lớp ẩn (hidden layer) và lớp đầu ra (output layer). Các lớp này được kết nối với nhau thông qua các synapse với trọng số khác nhau, và số lượng kết nối giữa các nơ-ron trong các lớp có thể được điều chỉnh tùy thuộc vào mục đích sử dụng. Trong phạm vi của bài

báo này, nhóm tác giả triển khai hai cấu trúc mạng feedforward: mạng feedforward nhỏ và mạng feedforward lớn, nhằm đánh giá hiệu quả của việc lựa chọn cấu trúc mạng với số kết nối phù hợp cho mục tiêu nhận dạng và chẩn đoán bệnh động kinh từ tín hiệu điện não. Mạng Feedforward thường được huấn luyện bằng các quy tắc học Hebbian, cụ thể là quy tắc STDP (Spike-Timing-Dependent Plasticity) [13]. Trong đó, các xung từ nơ-ron tiền synaptic (presynaptic spikes) xảy ra vài ms trước các xung từ nơ-ron hậu synaptic (postsynaptic spikes) sẽ dẫn đến khớp thần kinh sẽ tăng cường (long-term potentiation - LTP) tức tăng trọng số, trong khi các xung từ nơ-ron hậu synaptic xảy ra trước vài ms các xung từ nơ-ron trước synaptic sẽ dẫn đến sự giảm của khớp thần kinh (long-term depression - LTD) tức giảm trọng số.

Dưới đây là phương trình 1, 2 cơ bản mô tả mô hình học STDP.

$$W(x) = A_+ e^{-\frac{x}{\tau_+}} \quad \text{với } x > 0 \quad (1)$$

$$W(x) = A_- e^{-\frac{x}{\tau_-}} \quad \text{với } x < 0 \quad (2)$$

Các hằng số thời gian τ_+ và τ_- có giá trị khoảng 10ms, và các tham số A_+ và A_- là các siêu tham số xác định tốc độ thay đổi trọng số W , x là khoảng thời gian giữa xung tiền synapse và xung hậu synapse. Từ phương trình 1, nếu khoảng thời gian $x > 0$ nghĩa là các xung từ nơ-ron tiền synaptic xảy ra trước các xung từ nơ-ron hậu synaptic điều này sẽ làm W tăng và ngược lại W sẽ giảm ở phương trình 2. Trong nghiên cứu của nhóm tác giả trọng số được nhóm tác giả giới hạn trong khoảng 0 đến 500.

Cuối cùng, hệ thống sẽ phân loại các xung này thành hai nhóm: xung động kinh và xung không động kinh. Quy trình này giúp nhận diện và phân loại hiệu quả các xung động kinh từ dữ liệu EEG, hỗ trợ trong việc chẩn đoán và theo dõi tình trạng động kinh.

3. Triển khai thực nghiệm


Trong nghiên cứu này, tín hiệu EEG từ các bệnh nhân động kinh được thu thập và xử lý để tạo ra các tập dữ liệu. Sau đó, nhóm tác giả xây dựng một SNNs với kiến trúc mạng truyền thẳng để phân tích và nhận dạng các cơn động kinh. Các tham số của mạng như số lượng nơ-ron, kết nối và quy tắc học được tối ưu hóa để đạt hiệu suất tốt nhất.

3.1. Chuẩn bị cơ sở dữ liệu

Dữ liệu cho bài báo này là các tín hiệu điện trường cục bộ (Local Field Potentials - LFPs) được ghi lại từ các lát cắt của hồi hải mã bằng một mảng điện cực siêu nhỏ (Micro Electrode Array - MEA) [18]. Mỗi bản ghi bao gồm 28 điện cực, đo LFP tại các điểm gần nhau trong hồi hải mã. Mỗi luồng dữ liệu được gắn nhãn thành ba loại: giai đoạn cơ bản (baseline), giai đoạn giữa các cơn động kinh (interictal), và giai đoạn cơn động kinh (ictal) [16]. Giai đoạn ictal biểu thị khi có cơn động kinh xảy ra trong não, trong khi giai đoạn interictal là các hoạt động bất thường của não xảy ra giữa các giai đoạn ictal. Giai đoạn baseline là khi không có bất thường nào được ghi nhận. Tập dữ liệu bao gồm ba lần ghi lại vào ba ngày khác nhau, mỗi lần ghi kéo dài từ 1200 giây đến 1700 giây, là chuỗi 2,4 triệu giá trị đo điện áp theo thời gian. Một nửa số điện cực trong tập dữ liệu đo được cả các sự kiện giữa cơn co giật (interictal)

và các sự kiện co giật (ictal), trong khi nửa còn lại chỉ đo được các sự kiện co giật. Điều này là do vị trí của các điện cực. Cơn co giật sẽ không xảy ra tại cùng một thời điểm ở các vị trí khác nhau trong não, do đó có một độ trễ nhỏ giữa các cơn co giật tại các điện cực trong cùng một não bộ.

Trong Hình 4, một ví dụ về dữ liệu cùng với các nhãn tương ứng được thể hiện.

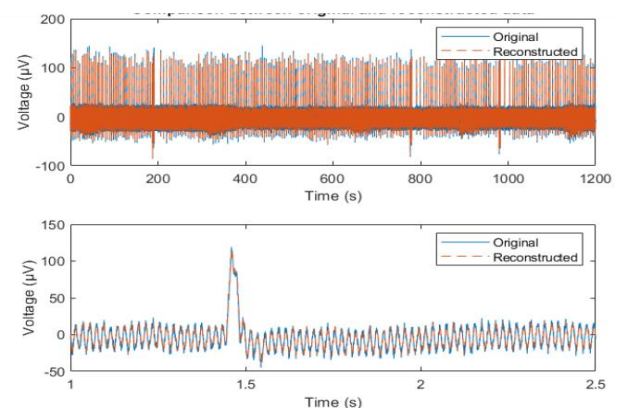


Hình 4. Ví dụ về dữ liệu từ một điện cực. Biểu đồ trên hiển thị dữ liệu LFP, và biểu đồ dưới hiển thị các nhãn (0 = trạng thái nền, 1 = giữa cơn co giật, 2 = cơn co giật)

3.2. Tối ưu hóa Mã hóa chuyển tiếp SFE


Phương pháp này tạo ra hai chuỗi xung, một dương và một âm. Chuỗi xung dương chứa các đoạn dốc dương của tín hiệu, còn chuỗi xung âm chứa các đoạn dốc âm. Thường khi đưa vào SNN, hai chuỗi này được gộp lại thành một chuỗi xung, vì các xung âm không thể xử lý trực tiếp.

Đối với dữ liệu LFP sử dụng trong nghiên cứu này, tỷ lệ phát xung trung bình (AFR) xấp xỉ 33%, nghĩa là trung bình cứ ba mẫu thì sẽ phát một xung. Trong Hình 5, so sánh giữa tín hiệu gốc và tín hiệu tái tạo được hiển thị. Tín hiệu tái tạo theo sát tín hiệu gốc, chỉ với một sai lệch nhỏ, do ngưỡng được đặt.



Hình 5. So sánh trực quan giữa dữ liệu gốc và dữ liệu tái tạo sử dụng mã hóa Step-Forward

Ngưỡng để phát xung được xác định bằng cách tìm giá trị có sai số bình phương trung bình (MSE) thấp nhất giữa dữ liệu gốc và dữ liệu tái tạo. Kết quả tìm kiếm tối ưu này có trong Hình 6, quá trình tìm kiếm giá trị lỗi bình phương trung bình thấp nhất (MSE) được thực hiện. Việc tìm kiếm được thực hiện với ngưỡng từ 1 đến 20, tăng dần từng bước 0,1. Kết quả tối ưu tìm được là 4,6, với MSE là 16,3.




Hình 6. tìm ngưỡng tối ưu bằng MSE

3.3. Triển khai cấu trúc mạng Feedforward

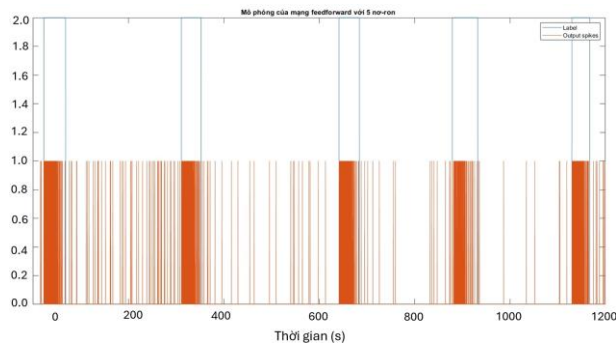
Như đã mô tả trước đó, mạng chuyên tiếp (feedforward) là cấu trúc mạng đơn giản nhất. Tuy nhiên, khi áp dụng để phân loại, một số tham số có thể được điều chỉnh để đạt kết quả tối ưu. Kích thước và cấu trúc của mạng, cũng như các mô hình nơ-ron, sẽ có ảnh hưởng lớn đến kết quả. Sau đây là nghiên cứu về kết quả xử lý dữ liệu với các mạng chuyên tiếp khi thay đổi kích thước và cấu trúc mạng, số lượng khớp thần kinh hưng phấn/ức chế và các cơ chế học.

3.3.1. Mạng Feedforward Nhỏ

Mạng đầu tiên được mô phỏng bao gồm 5 nơ-ron LIF (Leaky Integrate-and-Fire) [14], [15], được kết nối như thể hiện trong Hình 7. Các xung dương từ việc mã hóa được truyền vào nơ-ron ở tầng đầu vào phía trên, trong khi các xung âm được đưa vào nơ-ron ở tầng đầu vào phía dưới. Hai nơ-ron này được kết nối với tầng ẩn thông qua một synapse kích thích tĩnh theo phương thức một-một.



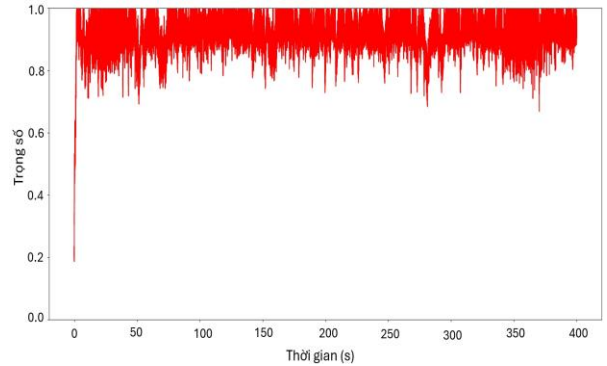
Hình 7. Kiến trúc của một mạng feedforward rất đơn giản gồm ba lớp. Các xung dương từ SFE được đưa vào nơ-ron phía trên, trong khi các xung âm được đưa vào nơ-ron phía dưới



Hình 8. Các xung tại nơ-ron đầu ra từ mạng trong Hình 4 ($1=Xung$ tại nơ-ron đầu ra), và các nhân ($2= Nhân$)

Các trọng số giữa tầng ẩn và đầu ra được khởi tạo với giá trị ngẫu nhiên trong khoảng từ 100 đến 200, và sau đó được huấn luyện bằng phương pháp STDP trong 400 giây. Kết quả được trình bày trong Hình 8, cho thấy các trọng số đã huấn luyện được giữ cố định trong suốt quá trình mô phỏng. Trong Hình 9, quá trình học của một synapse với STDP được thể hiện. Thời gian học diễn ra nhanh chóng

và trọng số hội tụ về giá trị tối đa. Giá trị cuối cùng đạt được là 0,95% của giá trị tối đa, cho thấy rằng trọng số hội tụ về trọng số tối đa cho phép. Cấu trúc huấn luyện này nhằm nâng cao độ chính xác của phản hồi mạng bằng cách tinh chỉnh trọng số của synapse để cải thiện hiệu quả phân ứng và lọc xung.



Hình 9. Quá trình huấn luyện của synapse với STDP cho mạng nhỏ gồm 5 nơ-ron

Mạng nơ-ron đã chỉ ra rằng, tần suất xung tăng nhanh khi có sự hiện diện của cơn co giật động kinh, cho thấy khả năng phát hiện cơn co giật. Nguyên nhân cho điều này có thể được tìm thấy trong nội dung tần số của tín hiệu LFP (điện thế trường cục bộ) từ não, vì tần số trong suốt cơn co giật thường tăng lên [16]. Việc mã hóa dữ liệu tương tự thành các chuỗi xung có khả năng bảo tồn nội dung tần số, cho phép mạng feedforward đơn giản lọc bỏ các khoảng thời gian tần số thấp và chỉ phát xung trong các khoảng thời gian tần số cao.


Trong thí nghiệm vừa trình bày, trọng số nhanh chóng đạt tới giá trị tối đa, điều này có nghĩa là nó sẽ còn tăng thêm nếu giới hạn trọng số cao hơn. Do đó, có thể cho rằng mạng này hoạt động chủ yếu do giới hạn trọng số, thay vì do quá trình học của synapse.

3.3.2. Mạng Feedforward lớn

Mặc dù, một mạng rất nhỏ đã chứng tỏ khả năng phát hiện cơn co giật, nhưng không thể kỳ vọng vào việc học tập mạnh mẽ. Do đó, một mạng ba lớp lớn hơn với 150 nơ-ron đã được tạo ra. Tầng đầu vào bao gồm 50 nơ-ron LIF, nơi các xung đầu vào được đưa vào qua một synapse tĩnh với trọng số được rút ra từ một phân phối chuẩn trước khi tạo ra mạng. Các xung đầu vào ở đây là các xung dương và âm từ SFE, được nối thành một vector duy nhất.

Mỗi nơ-ron trong tầng đầu vào (50 nơ-ron LIF) được kết nối với 10 nơ-ron ngẫu nhiên trong tầng ẩn (50 nơ-ron). 40 nơ-ron (80%) trong số này có trọng số synapse ban đầu được thiết lập từ một phân phối đồng nhất trong khoảng từ 0 đến 100. 10 nơ-ron còn lại (20%) có synapse được khởi tạo từ một phân phối đồng nhất trong khoảng từ -50 đến 0. STDP được sử dụng để huấn luyện trọng số của các synapse.

Các nơ-ron trong tầng ẩn được kết nối với tầng đầu ra (50 nơ-ron LIF) theo phương thức kết nối một-một. Các synapse này được huấn luyện theo cách tương tự như các synapse giữa tầng đầu vào và tầng ẩn. Quá trình học STDP diễn ra trong 400 giây và sau đó trọng số được giữ cố định. Đánh giá trọng số cho thấy, tất cả đều hội tụ về một giá trị sau 400 giây, nghĩa là thời gian học 400 giây là đủ. Mạng này được phác thảo trong Hình 10.



Hình 10. Kiến trúc của mạng feedforward lớn, với ba lớp và 50 nơ-ron trong mỗi lớp.

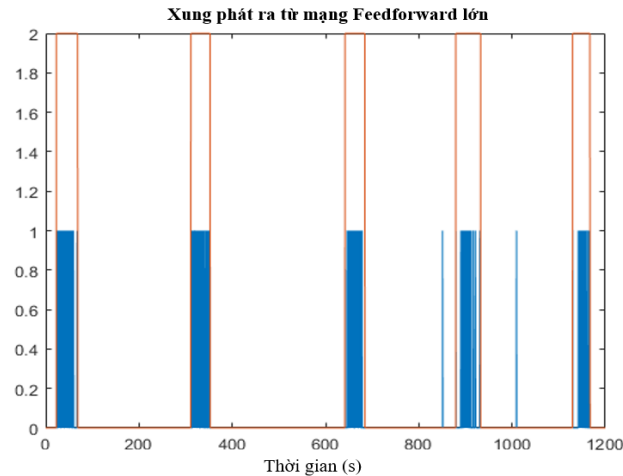
Quan sát các xung phát ra từ tất cả các nơ-ron trong tầng đầu ra cho phép phát hiện cơn co giật. Kết quả này được trình bày trong Hình 11. Mạng này giải quyết vấn đề phát xung giữa các cơn co giật, do đó không cần bất kỳ mạch hay quy trình nào để phát hiện tần số xung. Tuy nhiên, điều này đi kèm với việc mạng trở nên lớn hơn nhiều so với trước.

Mạng này có các synapse ức chế từ 20% nơ-ron của nó, và điều này đã cho kết quả tốt hơn so với việc giảm hoặc tăng tỷ lệ này. Khi giảm số lượng synapse ức chế, số lượng xung tại đầu ra tăng lên, dẫn đến hiện tượng phát xung giữa các cơn co giật, gây ra sự không rõ ràng trong việc phát hiện. Ngược lại, nếu tăng đáng kể tỷ lệ này (trên 35%), số lượng xung trong mạng sẽ giảm đi rất nhiều. Hệ quả là hiện tượng phát xung trở nên thưa thớt ở đầu ra, do đó không thể phát hiện đúng các sự kiện co giật.

$$\begin{aligned} \text{Độ chính xác} &= \frac{\text{Số lượng xung nhận diện đúng}}{\text{Tổng số xung cần nhận diện}} \\ &= \frac{TP + TN}{TP + FP + TN + FN} \quad (3) = \frac{23112000}{24000000} \approx 93,6\% \end{aligned}$$

Trong đó, TP (True Positive): SNN phát hiện đúng các xung co giật khi chúng thực sự xảy ra; TN (True Negative): SNN không phát hiện các xung co giật khi chúng thực sự không xảy ra; FP (False Positive): SNN phát hiện nhầm xung co giật khi thực tế không xảy ra; FN (False Negative): SNN bỏ sót các xung co giật khi chúng thực sự xảy ra.

Một yếu tố quan trọng để đạt được kết quả tốt là có một mạng cân bằng, với tỷ lệ tối ưu giữa các synapse kích thích và ức chế được đánh giá cẩn thận. Trong nghiên cứu này, tỷ lệ tốt nhất được tìm thấy là 20% ức chế và 80% kích thích, phù hợp với các nghiên cứu trước đây [17].

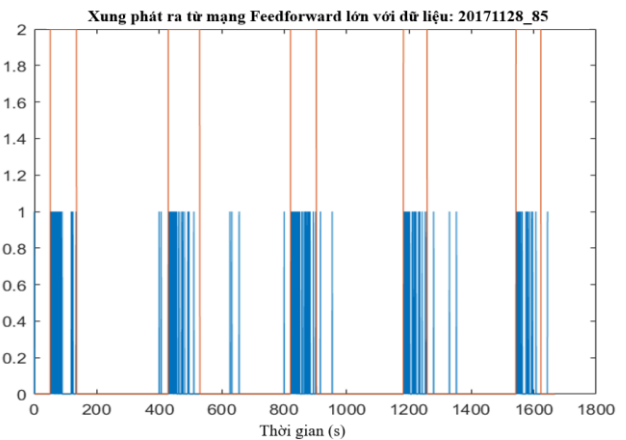


Hình 11. Các xung được thu thập từ tất cả 50 nơ-ron trong tầng đầu ra

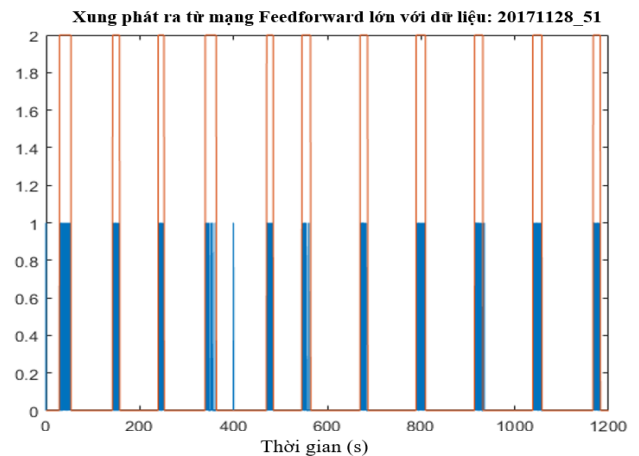
4. Kết quả và thảo luận

Các kết quả cho thấy rằng ngay cả một mạng đơn giản chỉ với 5 nơ-ron cũng có thể lọc được một lượng đáng kể các xung giữa các cơn co giật của bệnh động kinh, đồng thời vẫn duy trì được tần số cao của các xung khi có cơn co giật. Tuy nhiên, cấu hình này chưa đủ để phát hiện một cách đáng tin cậy, vì cần thêm logic bổ sung để nhận diện tần số xung cao một cách chính xác. Ngoài ra, việc học hiệu quả với một mạng nhỏ như vậy là một thách thức.

Việc mở rộng mạng lên 150 nơ-ron đã cho thấy hiệu suất được cải thiện, với chỉ một số ít xung xuất hiện ngoài các sự kiện co giật. Thời gian phát hiện trung bình đo được là 97 ms với độ chính xác tính theo phương trình 3:



Hình 12. Mạng feedforward lớn, dữ liệu thứ 85



Hình 13. Mạng feedforward lớn, dữ liệu thứ 51

Vì các kết quả được trình bày ở mục triển khai chỉ được thử nghiệm trên một điện cực dữ liệu, nên các mô phỏng bổ sung đã được thực hiện trên các điện cực khác để xác minh hiệu suất. Điều này được thực hiện trên 3.800 giây dữ liệu bổ sung, trong đó không có đào tạo thêm và các trọng số được cố định ở mức đã tìm thấy trước đó. Kết quả cho ra các đầu ra rất giống nhau, cho thấy phương pháp này có khả năng phát hiện cơn co giật từ các luồng dữ liệu khác nhau. Kết quả từ các thử nghiệm này được trình bày trong Hình 12 và Hình 13, có thể thấy rằng các xung co giật của bệnh động kinh cũng được nhận dạng đúng trong khung nhãn, chỉ vài xung nằm ngoài.

5. Kết luận

Khi được tối ưu hóa dữ liệu từ tín hiệu điện não đồ bằng thuật toán SFE, nghiên cứu tạo ra được các chuỗi xung có khả năng mã hóa tín hiệu tương tự với mức tổn thất tín hiệu thấp. Phương pháp mã hóa này có khả năng bảo tồn nội dung tần số của dữ liệu tương tự, điều này đặc biệt quan trọng khi làm việc với các cơn co giật động kinh, vì tần số thường tăng lên trong thời gian xảy ra cơn co giật. Một lợi ích khác là nó dễ dàng tối ưu hóa thông qua việc tìm kiếm đơn giản cho MSE thấp nhất, và tỷ lệ phát xung trung bình khi được tối ưu hóa thấp hơn 33%. Tỷ lệ phát xung thấp là có lợi, vì các nơ-ron chỉ được kích hoạt khi có xung, tức là năng lượng chỉ được tiêu thụ trong các sự kiện phát xung.

Các chuỗi xung sau khi được tạo ra đã được đánh giá dựa trên hai kiến trúc mạng khác nhau, đó là mạng feedforward nhỏ và lớn. Cả hai mạng đều có khả năng học cách phát hiện các cơn co giật động kinh từ các chuỗi xung. Tuy nhiên kết quả tốt nhất đạt được là độ trễ phát hiện 97 ms và độ chính xác là 96,3% cho mạng feedforward với 150 nơ-ron và với chỉ một số ít xung xuất hiện ngoài các sự kiện co giật.

Mạng nơ-ron xung với kiến trúc feedforward đã chứng minh là một giải pháp hiệu quả cho việc nhận dạng bệnh động kinh từ tín hiệu EEG. Nghiên cứu này mở ra hướng đi mới trong việc ứng dụng các công nghệ nơ-ron học vào y học, hứa hẹn mang lại những phương pháp điều trị tiên tiến hơn cho bệnh nhân động kinh. Trong tương lai, nhóm tác giả sẽ tiếp tục tối ưu hóa mô hình và mở rộng nghiên cứu trên nhiều loại dữ liệu hơn để nâng cao độ chính xác và khả năng tổng quát của hệ thống.

Lời cảm ơn: Bài báo này được tài trợ bởi Bộ Giáo dục và Đào tạo Việt Nam hỗ trợ theo cấp đề tài có mã số: B2023-DNA-12.

TÀI LIỆU THAM KHẢO

- [1] N. D. Anh, T. X. Tu, D. N. Khanh, and F. Iacopid, "A low-power, high-accuracy with fully on-chip ternary weight hardware architecture for Deep Spiking Neural Networks", *Microprocessors and Microsystems*, vol. 90, pp. 104458, April 2022. <https://doi.org/10.1016/j.micpro.2022.104458>.
- [2] A. Strzelczyk *et al.*, "The impact of epilepsy on quality of life", *Findings from a European survey*, *Epilepsy & Behavior*, vol. 142, pp. 109179, 2023. <https://doi.org/10.1016/j.yebeh.2023.109179>.
- [3] L. S. Boylan, L. A. Flint, D. L. Labovitz, S. C. Jackson, K. Stamer, and O. Devinsky, "Depression but not seizure frequency predicts quality of life in treatment-resistant epilepsy", *Neurology*, vol. 62, pp. 258–261, 2004. <https://doi.org/10.1212/01.wnl.0000103282.62353.85>
- [4] C. Marcin, P. Engelhart, J. Lerner, D. Dill, G. L'Italien, V. Coric, J. Matsumoto, and M. Potashman, "Determinants of Health-related Quality of Life of Patients with Focal Epilepsy: A Systematic Literature Review", *Neurology*, vol. 102, no. 17, pp. 9-1016, 2024. <https://doi.org/10.1212/WNL.00000000020482>.
- [5] J. Zhao, E. Donati, and G. Indiveri, "Neuromorphic Implementation of Spiking Relational Neural Network for Motor Control", in *2nd IEEE International Conference on Artificial Intelligence Circuits and Systems (AICAS)*, Genova, Italy, 2020, pp. 89-93. <https://doi.org/10.1109/AICAS48895.2020.9073829>.
- [6] S. G. Dastidar and H. Adeli, "Improved Spiking Neural Networks for EEG Classification and Epilepsy and Seizure Detection". *Integrated Computer-Aided Engineering*, vol. 14, no. 3, pp. 187-212, 2007. <https://doi.org/10.3233/ICA-2007-14301>
- [7] P. J. Grahm, G. W. Mallory, B. M. Berry, J. T. Hachmann, D. A. Lobel, and J. L. Lujan, "Restoration of motor function following spinal cord injury via optimal control of intraspinal microstimulation: toward a next generation closed-loop neural prosthesis". *Frontiers in Neuroscience*, vol. 8, pp. 296. 2014. <https://doi.org/10.3389/fnins.2014.00296>.
- [8] H. D. M. Ribeiro *et al.*, "ECG-based real-time arrhythmia monitoring using quantized deep neural networks: A feasibility study", *Computers in Biology and Medicine*, vol. 143, pp. 105249, 2022. <https://doi.org/10.1016/j.combiomed.2022.105249>
- [9] W. Maass, "Networks of spiking neurons: The third generation of neural network models", *Neural Networks*, vol. 10, no. 9, pp. 1659–1671, 1997. [https://doi.org/10.1016/S0893-6080\(97\)00011-7](https://doi.org/10.1016/S0893-6080(97)00011-7)
- [10] M. Bouvier, A. Valentian, T. Mesquida, F. Rummens, M. Reyboz, E. Vianello, and E. Beigne, "Spiking neural networks hardware implementations and challenges", *ACM Journal on Emerging Technologies in Computing Systems*, vol. 15, pp. 1–35, Apr. 2019
- [11] G. Panuccio, "Hermes", *hermes-fet.eu*, March, 2020. [Online]. Available: <https://hermes-fet.eu/> [Accessed March, 09, 2020].
- [12] N. Kasabov *et al.*, "Evolving spatio-temporal data machines based on the NeuCube neuromorphic framework: Design methodology and selected applications". *Neural Networks*, vol. 78, pp. 1–14, 2016. <https://doi.org/10.1016/j.neunet.2015.09.011>.
- [13] G. Bi and M. Poo, "Synaptic modification by correlated activity: Hebb's postulate revisited", *Annual Review of Neuroscience*, vol. 24, pp. 139–166, 2001. <https://doi.org/10.1146/annurev.neuro.24.1.139>.
- [14] W. Gerstner, W. M. Kistler, R. Naud, and L. Paninski, *Neuronal dynamics: from single neurons to networks and models of cognition*, Cambridge, United Kingdom: Cambridge University Press, 2014.
- [15] E. Izhikevich, "Simple model of spiking neurons", *IEEE Transactions on Neural Networks*, vol. 14, pp. 1569–1572, 2003.
- [16] R. S. Fisher, H. E. Scharfman, and M. deCurtis, "How can we identify ictal and interictal abnormal activity?", in *Issues in Clinical Epileptology: A View from the Bench*, pp. 3–23, Springer Netherlands, 2014.
- [17] W. Maass, T. Natschläger, and H. Markram, "Real-time computing without stable states: A new framework for neural computation based on perturbations", *Neural Computation*, vol. 14, pp. 2531–2560, 2002. <https://doi.org/10.1162/089976602760407955>.
- [18] G. Panuccio, I. Colombi, and M. Chiappalone, "Recording and modulation of epileptiform activity in rodent brain slices coupled to microelectrode arrays", *Journal of Visualized Experiments*, vol. 135, pp. 57548, 2018.