

راهکار جدیدی در تشخیص صرع براساس انتخاب بهترین ویژگی‌ها توسط تجزیه و تحلیل واریانس و شبکه سیامی

طیبه کشکولی ایلون¹، رامین براتی^{2*}، حمید آزاد³

¹¹ گروه مهندسی برق- واحد شیراز، دانشگاه آزاد اسلامی- شیراز- ایران

tayebehiloon@yahoo.com

² گروه مهندسی برق- واحد شیراز، دانشگاه آزاد اسلامی- شیراز- ایران

barati.ramin@aut.ac.ir

³ گروه مهندسی برق- واحد شیراز، دانشگاه آزاد اسلامی- شیراز- ایران

azad@shirazu.at.ir

چکیده: بیماری صرع را می‌توان طبق سازمان بهداشت جهانی، به عنوان تشنج‌های عودکننده مربوط به واکنش‌های فیزیکی که ناشی از تخلیه الکتریسته ناگهانی بر روی یک گروه از سلول‌های مغزی انسان تعریف کرد. سیگنال‌های الکتروانسفالوگرام (EEG) نقش مهمی در تشخیص این بیماری ایفا می‌کند. ثبت سیگنال‌های EEG که توسط دستگاه‌های ثبت سیار ضبط می‌شوند، اطلاعاتی با طول بسیار بالا تولید می‌کنند که تشخیص ناحیه صرعی نیازمند مدت زمان طولانی برای آنالیز کل اطلاعات توسط شخص متخصص می‌باشد. در سال‌های اخیر تعداد بسیار زیادی سیستم اتوماتیک برای تشخیص صرع بوجود آمده است. در این مقاله، رویکرد جدیدی در تشخیص بیماری صرع ارائه شده است. در ابتدا فرآیند پیش‌پردازش روی سیگنال‌های EEG اعمال و سپس با تبدیل موجک تجربی سیگنال به ده زیر سیگنال تجزیه می‌شود. پس از آن ویژگی‌ها استخراج و با استفاده از روش پیشنهادی تجزیه و تحلیل واریانس بهترین ویژگی‌ها انتخاب می‌شوند در نهایت، شبکه سیامی جهت کاهش ابعاد بردار ویژگی و الگوریتم ماشین بردار پشتیبان از این ویژگی‌ها جهت طبقه‌بندی سیگنال‌های EEG تشنج و غیرتشنج استفاده می‌شود. نتایج شبیه‌سازی روش پیشنهادی بر روی مجموعه داده‌های سیگنال EEG دانشگاه بن سبب دقت 100٪ شده است و این روش می‌تواند به طور مؤثر به پزشکان در تشخیص صرع کمک کند.

واژه‌های کلیدی: تشخیص بیماری صرع، سیگنال‌های الکتروانسفالوگرام، انتخاب ویژگی‌ها، شبکه سیامی،

1. مقدمه

صرع به عنوان یکی از مهم‌ترین اختلالات عصبی در جهان محسوب می‌شود که می‌تواند در همه گروه‌های سنی تأثیر بگذارد. در حال حاضر حدود 65 میلیون نفر در سراسر جهان از بیماری صرع رنج می‌برند [1]. صرع یک اختلال عصبی پایدار است که در آن تشنج با اختلالات ناخواسته ناگهانی و رفتارهای غیرقابل پیش بینی بیماران مشخص می‌شود. تشخیص صحیح و به موقع صرع برای شروع استفاده از داروهای کنترل‌کننده صرع و کاهش ریسک ابتلا به این بیماری، امری ضروری است. در حال حاضر، تشخیص صرع با آزمایش‌های نورولوژی و آزمایش‌های کمکی مثل تصاویر مغزی و EEG¹ حاصل می‌شود که EEG جایگاه خود را به عنوان پرکاربردترین رویکرد تشخیصی حفظ کرده است. با این وجود، اسکن بصری الکتروانسفالوگرام (EEG) برای تشخیص صرع هنوز هم بسیار پرهزینه، زمان‌بر و کاری نادرست است [2]. بنابراین ضروری است سیستم خودکار تشخیص کامپیوتری طراحی شود تا به طور خودکار، حالت‌های صرعی را از سیگنال EEG تشخیص دهد. این سیستم، به متخصصان جهت تشخیص دقیق و موثر بسیار کمک کننده می‌باشد.

تشخیص بیماری صرع به طور کلی با استفاده از الگوریتم یادگیری ماشین از سه مرحله، پیش‌پردازش، شناسایی ویژگی و طبقه بندی تشکیل شده است که مرحله شناسایی ویژگی‌ها یکی از مهم‌ترین مراحل می‌باشد. مرحله شناسایی ویژگی‌ها را می‌توان به سه مرحله، استخراج ویژگی‌ها، انتخاب ویژگی‌ها و تبدیل ویژگی‌ها تقسیم کرد که مراحل استخراج و انتخاب ویژگی‌ها در دقت تشخیص بیماری صرع بسیار حائز اهمیت می‌باشد و این امر سبب شده، هر روزه توجه محققانی بیشتری را به خود جلب کند که در ادامه که به مرور مواردی از آنها پرداخته می‌شود.

در [3] از آنتروپی طیفی، آنتروپی نمونه و آنتروپی فاز به عنوان ویژگی‌ها از سیگنال EEG برای تشخیص بیماری صرع استفاده شده است. در [4] جهت استخراج ویژگی‌ها، از ویژگی‌های آماری استفاده شده است. در [5] از ویژگی‌های توان شامل طیف توان نسبی، نسبت طیف توان و ضرایب همبستگی متقابل جهت تشخیص بیماری صرع استفاده شده است. در [6] از شبکه‌های یادگیری عمیق روی داده‌های EEG جهت استخراج ویژگی‌ها استفاده شده است. در [7] از تبدیل موجک و تحلیل غیرخطی RQA جهت استخراج ویژگی‌ها در تشخیص بیماری صرع استفاده شده است. در [8] از تبدیل موجک و محاسبه انرژی ضرایب موجک به عنوان ویژگی‌ها جهت تشخیص بیماری صرع استفاده شده است. در [9] از تبدیل موجک و الگوریتم K-means جهت استخراج ویژگی‌ها استفاده شده است. در [10] از روش‌های تخمین طیفی EV و MUSIC جهت استخراج ویژگی‌ها استفاده شده است. در [11] از روش تعمیم‌یافته تبدیل موجک و آنتروپی تقریبی جهت استخراج ویژگی‌ها و از الگوریتم ژنتیک جهت انتخاب ویژگی‌ها استفاده شده است. در [12] از الگوریتم جستجوی گرانشی باینری جهت انتخاب ویژگی‌ها استفاده شده است. در [13] از آنالیز autoregressive جهت استخراج ویژگی‌ها از سیگنال EEG استفاده شده است. در [14] از ترکیب روش‌های زمانی و فرکانسی جهت استخراج ویژگی‌ها استفاده شده است. در [15] از تبدیل مولتی ویولت و آنتروپی تقریبی به ترتیب جهت استخراج و انتخاب ویژگی‌ها استفاده شده است.

¹ Electroencephalogram

اگرچه تحقیقات فراوانی جهت تشخیص بیماری صرع انجام شده است اما هنوز چالش‌های در تعداد ویژگی‌های استخراج شده می‌باشد که در دقت تشخیص بیماری صرع بسیار موثر می‌باشد. تعیین تعداد ویژگی‌های استخراج شده از سیگنال EEG بسیار حائز اهمیت است، زیرا اگر از تعداد ویژگی‌های کمتری استفاده شود ممکن است اطلاعات کافی از سیگنال EEG جهت تشخیص بیماری صرع حاصل نشود و از طرف دیگر، اگر از تعداد ویژگی‌های زیادی استفاده شود منجر به *cruse of dimensional* می‌شود که سبب پیچیدگی محاسباتی در مراحل بعدی می‌شود. بنابراین، تعداد ویژگی‌ها باید به حد کافی باشد که از یک طرف، بتواند اطلاعات موثر از سیگنال EEG استخراج شود و از طرف دیگر منجر به *cruse of dimensional* نشود. این لازم به پیشنهاد یک روش مناسب جهت استخراج و انتخاب ویژگی‌های مناسب از سیگنال EEG می‌باشد.

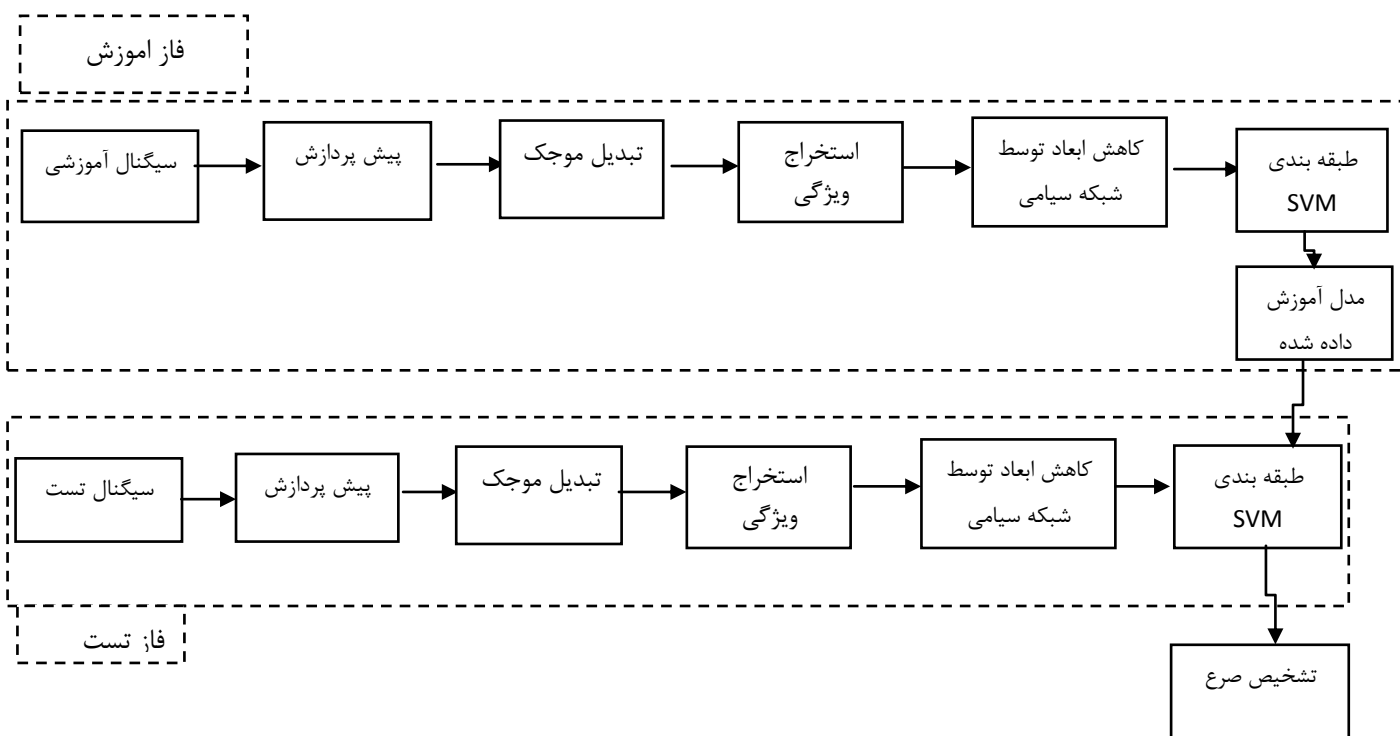
در این مقاله، با استفاده از ویژگی‌های مبتنی بر زمان، مبتنی بر فرکانس و مبتنی بر فرکانس-زمان، 165 ویژگی از سیگنال EEG استخراج می‌شود که بتواند اطلاعات کافی از این سیگنال حاصل شود. سپس برای جلوگیری از *cruse of dimensional* و کاهش پیچیدگی محاسباتی از پیشنهاد معیاری براساس تجزیه و تحلیل واریانس جهت انتخاب بهترین ویژگی‌ها و شبکه سیامی² جهت کاهش ابعاد استفاده می‌شود. در نهایت، از الگوریتم ماشین بردار پشتیبان جهت طبقه‌بندی سیگنال EEG استفاده می‌شود.

سازمان‌دهی بقیه مقاله به این صورت است که در بخش دوم به شرح روش پیشنهادی جهت تشخیص بیماری صرع، در بخش-های سوم و چهارم به ترتیب به نتایج و آزمایش‌ها و نتیجه‌گیری و پیشنهادها پرداخته می‌شود.

2. روش پیشنهادی

در این بخش فرایند تشخیص بیماری صرع در دو مرحله، آموزش و تست مطابق شکل (1) تشکیل شده است که در مرحله آموزش جهت استخراج قوانین از سیگنال‌های EEG و در مرحله تست از قوانین تولید شده جهت طبقه‌بندی سیگنال جدید استفاده می‌شود. به طور کلی پنج مرحله، پیش پردازش، تبدیل موجک جهت تجزیه سیگنال EEG، استخراج ویژگی‌ها، کاهش ابعاد ویژگی‌ها مبتنی بر شبکه یادگیری سیامی و طبقه‌بندی در هر یک از مراحل آموزش و تست به طور مجزا انجام می‌شود که در ادامه به شرح این پنج مرحله پرداخته می‌شود.

² Siamese



شکل (1): دیاگرام روش پیشنهادی

1-2. پیش پردازش

سیگنال الکتروانسفالوگرافی شامل نویزهای از جمله، نویز برق شهر و نویز حاصل از چشمک زدن، حرکات چشمی و همچنین آرتیفکت‌های ماهیچه‌ای است که جهت استفاده از این سیگنال‌ها لازم است از روش فیلترینگ FIR استفاده کرد. فیلترینگ موردنظر در اینجا از دو فیلتر FIR تشکیل شده است. یک فیلتر میان‌گذر با باند فرکانسی 40-50 هرتز که مربوط به فرکانس برق شهر، را رد می‌کند. دیگری یک فیلتر میان‌گذر که بازه فرکانسی 0/5-30 هرتز را عبور می‌دهد. سپس بعد از حذف نویز، سیگنال EEG به بخشهایی با طول ثابت، تقسیم می‌شوند. در این راستا، طول سیگنالی که در این مقاله مورد بررسی قرار می‌گیرد: 512 نمونه، 1024 نمونه، 2048 نمونه و کل طول (4097 نمونه) سیگنال EEG است.

2-2. تبدیل موجک تجربی

در این بخش از روش تبدیل موجک تجربی جهت تجزیه سیگنال EEG به ده زیرسیگنال استفاده می‌شود. تبدیل موجک تجربی، روش تجزیه تطبیق‌پذیر است که توسط گیلز معرفی شده است [16]. در این رویکرد از مجموعه‌ای موجک‌ها که موجک تجربی نامیده می‌شوند، برای تجزیه هر سیگنال به مولفه‌هایش استفاده می‌شود. این موجک‌ها طبق اطلاعات فرکانسی موجود در سیگنال‌ها تعیین می‌شوند، بنابراین می‌توان گفت که روش تبدیل موجک تجربی از روش تجزیه مود تجربی الهام گرفته شده است. ساخت خانواده‌ای از موجک تجربی، معادل تشکیل مجموعه‌ای از فیلترهای میان‌گذر است. از آنجایی که هر مود معادل یک فرکانس خاص است، بنابراین در روش تبدیل موجک تجربی، طیف فرکانسی نرمال شده هر سیگنال را به N بخش، $N-1$ ماکزیمم محلی در طیف

سیگنال با بیشترین دامنه تعیین می‌شوند. مرز هر بخش توسط فرکانس تعیین می‌شوند که مراحل این الگوریتم در ادامه شرح داده می‌شود.

مرحله اول: محاسبه طیف فوریه $X(\omega)$ در محدوده فرکانس $[0, \pi]$ ، سیگنال $x(t)$ با استفاده از الگوریتم تبدیل فوریه سریع، سپس همه ماکزیمم محلی $M = \{M_i\}, i=1,2,\dots,m$ از $X(\omega)$ و فرکانسهای مربوط به آنها را $w_i, i=1,2,\dots,m$ استنباط می‌کند.

مرحله دوم: در این مرحله، طیف فوریه به N بخش تقسیم می‌شود. در این مطالعه، تعداد سیگنال‌های زیر باند N برای هر سیگنال EEG به 10 ثابت می‌شود. مرز هر بخش مطابق فرمول (1) محاسبه می‌شود.

$$\Omega_i = \frac{w_i + w_{i+1}}{2} \quad (1)$$

مرحله سوم: در این مرحله، یک بانک فیلتر تطبیقی از فیلتر موجک m در هر بخش مطابق با ایده حاکم بر تولید موجک‌های لیتل وود پلی و میر، تابع مقیاس‌گذاری و موجک‌های تجربی مطابق فرمول‌های (2-3) بدست می‌آید [16].

$$\Phi_1(\Omega) = \begin{cases} 1, & |\Omega| \leq (1-\theta)\Omega_1 \\ \cos\left(\frac{\pi\Theta(\theta, \Omega_i)}{2}\right), & (1-\theta)\Omega_1 \leq |\Omega| \leq (1+\theta)\Omega_1 \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

$$\psi_i(\Omega) = \begin{cases} 1, & (1+\theta)\Omega_i \leq |\Omega| \leq (1-\theta)\Omega_{i+1} \\ \cos\left(\frac{\pi\Theta(\theta, \Omega_i)}{2}\right), & (1-\theta)\Omega_{i+1} \leq |\Omega| \leq (1+\theta)\Omega_{i+1} \\ \sin\left(\frac{\pi\Theta(\theta, \Omega_i)}{2}\right), & (1-\theta)\Omega_i \leq |\Omega| \leq (1+\theta)\Omega_{i+1} \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

که در این روابط، $\Theta(\theta, \Omega_i) = a\left(\frac{(|\Omega|) - (1-\theta)\Omega_i}{2\theta\Omega_i}\right)$ و $a(x)$ تابعی اختیاری است که مطابق (4) تعریف می‌شود.

$$\alpha(x) = \begin{cases} 0, & x \leq 0 \\ \alpha(x) + \alpha(1-x) = 1, & 0 \leq x \leq 1 \\ 1, & x \geq 1 \end{cases} \quad (4)$$

وضعیت فریم تنگ در $L^2(R)$ از توابع موجک و مقیاس‌گذاری تجربی زمانی است که شرایط زیر رخ دهد.

$$\theta \langle \min_i \left(\frac{\Omega_{i+1} - \Omega_i}{\Omega_{i+1} + \Omega_i} \right) \rangle$$

(5)

ضرایب تقریبی (cA_1) و ضرایب جزئیات (cD_i) مطابق فرمولهای (6-7) بدست می‌آید.

$$cA_1 = \langle x(t), \Phi_1 \rangle = \int x(\tau) \overline{\Phi}_1(t - \tau) d\tau$$

(6)

$$cD_i = \langle x(t), \psi_i \rangle = \int x(\tau) \overline{\psi}_i(t - \tau) d\tau$$

(7)

سرانجام، سیگنال‌های زیر باند $x(t)$ مطابق فرمول (8) بدست می‌آید.

$$x(t) = cA_1 * \Phi_1 + \sum_{i=1}^N cD_i * \psi_i$$

(8)

که در آن، نماد * نمایانگر عملیات کانولوشن است.

3-2. استخراج ویژگی

روش‌های استخراج ویژگی به طور کلی به سه دسته، مبتنی بر زمان، مبتنی بر فرکانس و مبتنی بر فرکانس-زمان تقسیم می‌شوند که اخیراً تحقیقات نشان دهنده اینست که ترکیب هر سه روش جهت بهبود دقت تشخیص خودکار صرع بسیار موثرتر است [17-19]. در جدول (1) لیستی از ترکیب هر سه روش ویژگی‌های استفاده شده در این مقاله معرفی شد.

جدول (1): لیستی از ویژگی‌های استخراج شده

روابط ویژگی‌ها	نوع ویژگی‌ها	شماره
$\mu_a = \frac{1}{N} \sum_{i=1}^N a_i$	میانگین	1
$\sigma_a = \sqrt{\frac{1}{N-1} \sum_{i=1}^N a_i - \mu_a ^2}$	انحراف استاندارد	2
$V_a = \frac{1}{N-1} \sum_{i=1}^N a_i - \mu_a ^2$	واریانس	3
$S_a = \frac{R_3}{R_2 \sqrt{R_2}}, R_k = \frac{1}{N} \sum_{i=1}^N a_i - \mu_a ^k$	انحراف	4
$K_a = \frac{R_4}{R_2 R_2}, R_k = \frac{1}{N} \sum_{i=1}^N a_i - \mu_a ^k$	کورتوز	5
$L_a = \sum_{i=1}^{N-1} a_i - a_{i-1} $	طول خط	6
$NE_a = \sum_{i=2}^{N-1} a_i^2 - a_{i+1} a_{i-1} $	انرژی غیرخطی	7
$SEn(a, m, r) = \log \phi^m(r) - \log \phi^{m+1}(r)$ $\phi^m(r) = \sum_{j=0}^{N-m} \sum_{i=0}^{N-m} \Theta(r - \ a_i - a_j\ _\infty)$ where $\Theta(\cdot)$ is Heaviside step function	SampEn	8
$PEN(a) = -\sum_{k=1}^{m!} p(\pi_k) \log p(\pi_k).$ $p(\pi_k) = \frac{1}{N-m+1} \sum_{i=0}^{N-m} \delta[a_i - \pi_k]$ where $\delta(\cdot)$ is Dirac function	آنتروپی جایگشت	9
$ShEn(a) = -\sum_{i=1}^N p_i \log p_i.$	آنتروپی شانون	10
$SpEn(a) = -\sum_{i=1}^N p_f \log p_f.$	آنتروپی طیفی	11
$M_a = \frac{\sigma_{a'}}{\sigma_a}, a'_i = a_{i+1} - a_i$	تحرک	12
$C_a = \frac{\sigma_{a''} / \sigma_{a'}}{\sigma_{a'} / \sigma_a}, a''_i = a'_{i+1} - a'_i$	پیچیدگی	13
NZ_a	Number of zero-crossings تعداد عبور از صفر	14
NX_a	تعداد اکسترمم محلی	15

پانزده ویژگی از هر دو سیگنال EEG (سیگنال خام و ده زیر باندهای تجزیه شده توسط الگوریتم تبدیل موجک تجربی) استخراج می‌شود که در نهایت $165 = (1+10) \times 15$ ویژگی از این دو سیگنال شناسایی می‌شود. برخی از این ویژگی‌ها ممکن است زائد باشند که برای طبقه‌بندی مناسب نیستند. حذف ویژگی‌های زائد امری بسیار ضروری است که در این مقاله، از روش رتبه‌بندی ویژگی‌ها استفاده می‌شود و ویژگی‌های استخراج شده با توجه به اهمیت آنها برای تشخیص صرع طبقه‌بندی می‌شوند. در اینجا از 165 ویژگی، 30 ویژگی رتبه بالا با استفاده از تجزیه و تحلیل واریانس³ (ANOVA) انتخاب می‌شوند. به طور خاص، ANOVA برای انتخاب مناسب‌ترین ویژگی‌ها براساس بردار رتبه‌بندی ویژگی‌ها با محاسبه مقدار F برای هر ویژگی استفاده می‌شود. به طور کلی، ویژگی‌هایی با مقادیر بالاتر F نسبت به طبقه‌بندی نهایی قابل توجه‌تر هستند [20].

4-2. شبکه سیامی

شبکه‌های عصبی سیامی اولین بار در اوایل سال 1990 میلادی توسط بروملی و لیکان⁴ برای حل مسئله تشخیص امضاء به عنوان یک مسئله‌ی تطبیق تصویر⁵ مورد استفاده قرار گرفت [21]. یک شبکه عصبی سیامی شامل یک جفت شبکه با ورودی‌های مجزا با وزن‌های مشابه است، که در آخرین لایه توسط یک تابع زیان به یکدیگر متصل می‌شوند. این نوع از شبکه‌ها همچون سایر انواع شبکه‌های عصبی با الگوریتم پس انتشار آموزش می‌بینند. در این نوع از شبکه‌ها وزن‌ها بین جفت شبکه عصبی کانولوشن به اشتراک گذاشته می‌شوند. فرض کنید، x_i یک بردار p بعدی از فضای ورودی است، $f(x) \in R^q$ یک نمایه غیرخطی برای شبکه عصبی پرسپترون چند لایه⁶ است که بردار را به یک فضای اقلیدسی بصورت ابعادی q تبدیل می‌کند. بنابراین، تابع زیان جهت آموزش شبکه سیامی مطابق رابطه (9) محاسبه می‌شود.

$$Loss(D, Y) = (1 - Y) \times D + Y \times \max(a - D, 0) \quad (9)$$

در رابطه (8)، متغیر باینری Y صفر است وقتی که جفت به همان کلاس تعلق دارند و متغیر باینری Y یک است وقتی که جفت به آن کلاس تعلق ندارد و D یک شاخص فاصله بین یک جفت نمونه است. تابع زیان سعی می‌کند، حداقل فاصله بین کلاس و حداکثر فاصله درون کلاس را داشته باشد. تابع زیان کل جهت آموزش شبکه سیامی برای N جفت‌های آموزشی تولید شده مطابق رابطه (10) بدست می‌آید.

$$Total_Loss = \sum_{i=1}^N Loss(D_i, Y_i) \quad (10)$$

³ Analysis of variance(ANOVA)

⁴ Bromley and Le Cun

⁵ Image matching

⁶ Multi-layer perceptron(MLP)

در ساختار پیشنهادی جهت کاهش ابعاد بردار ویژگی‌ها، هر زیر شبکه، یک شبکه عصبی پرسپترون چند لایه (MLP)، از پنج لایه کاملاً متصل، یک لایه ورودی، سه لایه پنهان و یک لایه خروجی تشکیل شده است. تعداد نورون‌های لایه ورودی و لایه خروجی را می‌توان با توجه به ابعاد ویژگی انتخاب کرد و ابعاد ویژگی نهایی به ترتیب برابر 30 و 2 تعیین کرد. با این حال، تعیین تعداد نورون-ها در هر لایه پنهان یک فرایند آزمایش و خطا است. بنابراین، فرایند آزمایش تکراری برای تعیین تعداد نورون برای هر لایه پنهان استفاده شد (در این مقاله از 20 نورون، ده نورون و پنج نورون به ترتیب برای لایه‌های پنهان 1، 2 و 3 استفاده شده است).

5-2. طبقه‌بندی

SVM یکی از روش‌های یادگیری با نظارت است که در این مقاله از آن برای طبقه‌بندی ویژگی‌های انتخابی استفاده می‌شود [22]. مبنای کار طبقه‌بند SVM دسته‌بندی خطی داده‌ها است و در تقسیم داده‌ها سعی می‌شود، خطی انتخاب شود که حاشیه اطمینان بیشتری داشته باشد. تابع جداساز برای SVM دو کلاسه، مطابق فرمول (11) می‌باشد.

$$f(x) = \sum_{i=1}^n y_i a_i k(x, x_i) + b \quad (11)$$

در رابطه (11)، n تعداد نمونه‌های آموزشی، x_i نمونه آموزشی i ام و y_i طبقه صحیح برای نمونه آموزشی i ام است. مقدار y_i برای یکی از کلاس‌ها 1 و برای کلاس دیگری -1 در نظر گرفته می‌شود و b مقدار بایاس تابع است. مقادیر a_i ضرایب طبقه‌بند هستند که به همراه b در حین آموزش تعیین می‌شوند. تابع $k(x_1, x_2)$ هسته است که دو نمونه از متدوال‌ترین هسته‌هایی که برای SVM استفاده می‌شوند، به ترتیب مطابق روابط (12-13) می‌باشد.

$$k(x_1, x_2, p) = (1 + x_2 \cdot x_1)^p \quad (12)$$

$$k(x_1, x_2, \sigma) = e^{-\frac{\|x_1 - x_2\|^2}{2\sigma^2}} \quad (13)$$

در روابط (12-13) p و σ به ترتیب پارامترهای قابل تنظیم برای هسته‌های چندجمله‌ای و RBF هستند. ضرایب a_i در رابطه (11)، با حل مسائل بهینه‌سازی مطابق رابطه (14) بدست می‌آید.

$$w(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j k(x_i, x_j) \quad (14)$$

اثر SVM بستگی به انتخاب هسته، پارامترهای هسته، دارد که در این مقاله از تابع هسته RBF برای SVM استفاده شده است چون تابع هسته RBF می‌تواند داده با ابعاد بالا را آنالیز کند.

3- نتایج

در این بخش، ابتدا معیارهای ارزیابی روش‌های تشخیص بیماری صرع مورد بررسی قرار خواهد گرفت و پس از آن، دیتابیس مورد استفاده در مقاله معرفی خواهد شد. در نهایت نتایج عملی تشخیص بیماری صرع با روش پیشنهادی و مقایسه آن با روش‌های کلاسیک آخرین زیربخش این قسمت خواهد بود.

3-1- معیارهای ارزیابی

برای ارزیابی کارایی روش‌های تشخیص بیماری صرع از معیارهای ارزیابی کلاسیک، صحت مطابق رابطه‌ی (15)، حساسیت ویژگی‌ها مطابق رابطه‌ی (16) و نرخ ویژگی (خاص بودن⁷) مطابق رابطه‌ی (17) استفاده می‌شود. هرچه مقدار صحت، حساسیت ویژگی‌ها، ویژگی بیشتر، مناسب‌تر است.

$$ACC = \frac{TP + TN}{TP + FP + TN + FN} \quad (15)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (16)$$

$$Specificity = \frac{TN}{TN + FP} \quad (17)$$

در این روابط (15-17)، مثبت واقعی TP و منفی واقعی TN به ترتیب تعداد سیگنال‌های EEG به درستی شناسایی شده و تعداد سیگنال‌های EEG به درستی رد شده را برای هر کلاس نشان می‌دهند. همچنین، منفی کاذب FN و مثبت کاذب FP تعداد سیگنال‌های EEG اشتباه رد شده و سیگنال‌های EEG اشتباه تشخیص داده شده برای هر کلاس هستند.

3-2- نتایج و آزمایش‌ها

برای ارزیابی عملکرد روش پیشنهادی با روش [23]، روش [24] و روش [25] دو مجموعه آزمایش انجام می‌شود. در مجموعه آزمایش اول، تاثیر طول‌های مختلف سیگنال EEG بر روی عملکرد روش پیشنهادی، از مجموعه داده‌های سیگنال EEG دانشگاه بن استفاده شده است که این مجموعه داده از پنج مجموعه داده فرعی تشکیل شده است که دارای علائم Z (بیدار و چشمان باز)، O (بیدار و چشمان بسته)، N (نمونه‌های ضبط شده از بیماران در فواصل حملات صرع)، F (نمونه‌های ضبط شده از بیماران در فواصل حملات صرع) و S (سیگنال‌های الکتروانسفالوگرافی افراد در حین حملات صرع که توسط دستگاه EEG ضبط شده) هستند با خصوصیتی که در جدول (2) آمده است. در مجموعه آزمایش دوم، جهت مقایسه عملکرد روش پیشنهادی با روش‌های دیگر از این مجموعه تصاویر استفاده و کارایی آن‌ها بررسی می‌شود.

⁷ Specificity

جدول(2): موردهای متفاوت در نظر گرفته شده

مورد	کلاسها	توصیف	نوع
1	S با Z	نمونه غیرصرعی و حین تشنج	دو کلاس
2	S با O		
3	S با ZO		
4	S با N	نمونه فاصله بین تشنجها و حین تشنج	دو کلاس
5	S با F		
6	S با NF		
7	S با NZO	نمونه بدون تشنج و نمونه تشنج	دو کلاس
8	S با FZO		
9	S با ZONF		
10	S با N با Z	نمونه غیرصرع، فاصله بین تشنجها و حین تشنج	سه کلاس
11	S با NF با ZO		
12	S با F با N با O با Z		پنج کلاس

3-2-1. تاثیر طول موجهای مختلف سیگنال EEG

در این آزمایش، تاثیر طول های مختلف بخش بر صحت نهایی تشخیص تشنج بررسی شده است. در این راستا با استفاده از 4096 ، 2048 ، 1024 و 512 امتیاز چهار طول پنجره تعیین شد، به ترتیب، هر بخش EEG اصلی به 1 ، 2 ، 4 یا 8 بخش کوتاه تقسیم شد. برای هر پنجره ، عملکرد روش پیشنهادی مورد ارزیابی قرار گرفت (جدول 3).

جدول (3): ارزیابی عملکرد روش پیشنهادی با طول متفاوت سیگنال EEG

طول پنجره	مورد	صحت	حساسیت	ویژگی
512	1	100±0	100±0	100±0
	9	99.27±0.36	98.88±0.20	99.53±0.36
	11	99.32±0.29	98.95±0.36	99.68±0.21
	12	98.91±0.81	97.94±0.96	99.05±0.31
1024	1	100±0	100±0	100±0
	9	99.33±0.61	98.88±0.20	99.53±0.36
	11	99.88±0.16	98.95±0.36	99.73±0.12
	12	99.01±0.88	97.94±0.96	99.29±0.86
2048	1	100±0	100±0	100±0
	9	99.70±0.28	99.33±0.25	99.88±0.29
	11	99.89±0.21	99.95±0.03	99.75±0.08
	12	99.16±0.49	98.99±0.85	99.89±0.13
4096	1	100±0	100±0	100±0
	9	99.69±0.42	99.38±0.21	99.84±0.33
	11	99.95±0.01	100±0	99.89±0.13
	12	99.30±0.35	99.64±0.05	99.12±0.44

همان‌طور که در جدول 3 مشاهده می‌شود، دقت طبقه‌بندی، حساسیت و ویژگی با افزایش طول سیگنال بهبود می‌یابد. همچنین لازم به ذکر است که برای پنجره طول کوتاه، عملکرد مدل پیشنهادی با سایر روش‌های پیشرفته قابل مقایسه است.

2-2-3. مقایسه با کارهای اخیر انجام شده

در این بخش، عملکرد روش پیشنهادی با سایر روش‌های کلاسیک اخیر مقایسه شد که در جدول 4 نشان داده شده است.

جدول (4): مقایسه روش پیشنهادی با روش‌های دیگر

روش‌ها	دقت	حساسیت	ویژگی
روش [23]	79/8	81/5	77/2
روش [24]	93	97	92
روش [25]	98/40	98/22	98/31
روش پیشنهادی	99/30	99/64	99/12

همان‌طور که در جدول 4 مشاهده می‌شود، روش پیشنهادی عملکرد بهتری از جهت دقت، حساسیت و ویژگی نسبت به روش‌های کلاسیک اخیر دارد.

4- نتیجه گیری

در این مقاله، سیستم جدیدی برای تشخیص خودکار صرع با استفاده از پیش پردازش، تبدیل موجک، استخراج ویژگی‌ها، کاهش ابعاد ویژگی‌ها مبتنی بر شبکه یادگیری سیامی و طبقه‌بندی معرفی شد. در ابتدا، با استفاده از فیلتر FIR جهت حذف نویز و از تبدیل موجک تجربی جهت تجزیه سیگنال EEG به ده زیر سیگنال استفاده می‌شود. سپس با استفاده از ویژگی‌های مبتنی بر زمان، مبتنی بر فرکانس و مبتنی بر فرکانس- زمان، 165 ویژگی از سیگنال EEG استخراج می‌شود. پس از آن، با استفاده از روش پیشنهادی براساس تجزیه و تحلیل واریانس جهت انتخاب بهترین ویژگی‌ها و شبکه سیامی جهت کاهش ابعاد ویژگی‌ها به کار گرفته می‌شود. در نهایت، برای طبقه‌بندی سیگنال‌های EEG تشنج و غیر تشنج، الگوریتم ماشین بردار پشتیبان در نظر گرفته می‌شود. روش پیشنهادی در در تشخیص خودکار بیماری صرع عملکرد موثری دارد. در مطالعات آتی تلاش می‌شود که این روش پیشنهادی را بر روی پایگاه داده‌های دیگر همچون تشخیص آلزایمر و و طبقه‌بندی مراحل خواب نیز مورد بررسی قرار خواهد گرفت.

- [1] P. Boonyakitanont, A. Lek-uthai, K. Chomtho, and J. Songsiri, "A Comparison of Deep Neural Networks for Seizure Detection in EEG Signals," *bioRxiv*, p. 702654, 2019.
- [2] H. Ocak, "Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy," *Expert Systems with Applications*, vol. 36, pp. 2027-2036, 2009.
- [3] U. R. Acharya, F. Molinari, S. V. Sree, S. Chattopadhyay, K.-H. Ng, and J. S. Suri, "Automated diagnosis of epileptic EEG using entropies," *Biomedical Signal Processing and Control*, vol. 7, pp. 401-408, 2012.
- [4] D. S. T. Behara, A. Kumar, P. Swami, B. K. Panigrahi, and T. K. Gandhi, "Detection of epileptic seizure patterns in EEG through fragmented feature extraction," in *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, 2016, pp. 2539-2542.
- [5] Z. Zhang and K. K. Parhi, "Seizure prediction using long-term fragmented intracranial canine and human EEG recordings," in *2016 50th Asilomar Conference on Signals, Systems and Computers*, 2016, pp. 361-365.
- [6] N. D. Truong, A. D. Nguyen, L. Kuhlmann, M. R. Bonyadi, J. Yang, and O. Kavehei, "A generalised seizure prediction with convolutional neural networks for intracranial and scalp electroencephalogram data analysis," *arXiv preprint arXiv:1707.01976*, 2017.
- [7] M. Niknazar, S. Mousavi, B. V. Vahdat, and M. Sayyah, "A new framework based on recurrence quantification analysis for epileptic seizure detection," *IEEE journal of biomedical and health informatics*, vol. 17, pp. 572-578, 2013.
- [8] N. Sadati, H. R. Mohseni, and A. Maghsoudi, "Epileptic seizure detection using neural fuzzy networks," in *2006 IEEE international conference on fuzzy systems*, 2006, pp. 596-600.
- [9] U. Orhan, M. Hekim, and M. Ozer, "EEG signals classification using the K-means clustering and a multilayer perceptron neural network model," *Expert Systems with Applications*, vol. 38, pp. 13475-13481, 2011.
- [10] A. R. Naghsh-Nilchi and M. Aghashahi, "Epilepsy seizure detection using eigen-system spectral estimation and Multiple Layer Perceptron neural network," *Biomedical Signal Processing and Control*, vol. 5, pp. 147-157, 2010.
- [11] H. Ocak, "Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm," *Signal processing*, vol. 88, pp. 1858-1867, 2008.
- [12] A. Jain and D. Zongker, "Feature selection: Evaluation, application, and small sample performance," *IEEE transactions on pattern analysis and machine intelligence*, vol. 19, pp. 153-158, 1997.
- [13] S. Mousavi, M. Niknazar, and B. V. Vahdat, "Epileptic seizure detection using AR model on EEG signals," in *2008 Cairo International Biomedical Engineering Conference*, 2008, pp. 1-4.
- [14] L. Wang, W. Xue, Y. Li, M. Luo, J. Huang, W. Cui, *et al.*, "Automatic epileptic seizure detection in EEG signals using multi-domain feature extraction and nonlinear analysis," *Entropy*, vol. 19, p. 222, 2017.
- [15] L. Guo, D. Rivero, and A. Pazos, "Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks," *Journal of neuroscience methods*, vol. 193, pp. 156-163, 2010.
- [16] J. Gilles, "Empirical wavelet transform," *IEEE transactions on signal processing*, vol. 61, pp. 3999-4010, 2013.
- [17] U. R. Acharya, Y. Hagiwara, S. N. Deshpande, S. Suren, J. E. W. Koh, S. L. Oh, *et al.*, "Characterization of focal EEG signals: a review," *Future Generation Computer Systems*, vol. 91, pp. 290-299, 2019.
- [18] P. Boonyakitanont, A. Lek-Uthai, K. Chomtho, and J. Songsiri, "A review of feature extraction and performance evaluation in epileptic seizure detection using EEG," *Biomedical Signal Processing and Control*, vol. 57, p. 101702, 2020.
- [19] M. Ahmad, M. Saeed, S. Saleem, and A. M. Kamboh, "Seizure detection using EEG: A survey of different techniques", in *2016 International Conference on Emerging Technologies (ICET)*, 2016, pp. 1-6.
- [20] H. Kobayashi, B. L. Mark, and W. Turin, *Probability, random processes, and statistical analysis: applications to communications, signal processing, queueing theory and mathematical finance*: Cambridge University Press, 2011.

- [21] G. Koch, R. Zemel, and R. Salakhutdinov, "Siamese neural networks for one-shot image recognition," in *ICML deep learning workshop*, 2015.
- [22] C. J. Burges, "A tutorial on support vector machines for pattern recognition," *Data mining and knowledge discovery*, vol. 2, pp. 121-167, 1998.
- [23] T. Zhang, W. Chen, and M. Li, "Generalized Stockwell transform and SVD-based epileptic seizure detection in EEG using random forest," *Biocybernetics and Biomedical Engineering*, vol. 38, pp. 519-534, 2018.
- [24] M. Mahmud, M. S. Kaiser, A. Hussain, and S. Vassanelli, "Applications of deep learning and reinforcement learning to biological data," *IEEE transactions on neural networks and learning systems*, vol. 29, pp.2018 ,2079-2063 .
- [25] D.-T. Hoang and H.-J. Kang, "A survey on deep learning based bearing fault diagnosis," *Neurocomputing*, vol. 335, pp. 327-335, 2019.