

## یادگیری عمیق در تشخیص احساس از روی سیگنال های مغزی<sup>۱</sup> EEG در کاربرد سیستم رابط مغز و کامپیوتر BCI

شیرین رنجبران<sup>۱</sup>، نوشین رباحی<sup>۲</sup>

۱- گروه کامپیوتر، دانشکده فنی، دانشگاه الزهرا (س)، تهران، ایران

۲- استادیار گروه فنی، دانشگاه الزهرا (س)، تهران، ایران

نویسنده مسئول: shirin\_ranjbar@ymail.com

### خلاصه

تشخیص احساس یکی از وظایف مهم کامپیوتر برای فهمیدن حالت افراد در سیستم های واسط مغز و کامپیوتر (BCI) است. فهمیدن احساس برخی افراد ناتوان از طریق حالت صورت دشوار است، ثبت سیگنال های مغزی (EEG) روش غیرتهاجمی برای تشخیص احساس افراد ناتوان از طریق الکترودهای هدست EEG که بر روی جمجمه قرار می گیرد را میسر می سازد. این مقاله الگوریتم یادگیری عمیق<sup>۳</sup> به همراه یادگیری ویژگی ها<sup>۴</sup> و طبقه بندی<sup>۵</sup> احساسات از سیگنال EEG است و تفاوت های آن نسبت به روش های مرسوم، اعمال یادگیری عمیق بر روی سیگنال خام بدون استخراج ویژگی صریح و به صورت غیردستی می باشد.

**کلمات کلیدی:** یادگیری عمیق، سیگنال های مغزی EEG، ماشین بولزمن محدود شده لایه، یادگیری عمیق سیگنال، رابط مغز و کامپیوتر

### ۱. مقدمه

طبقه بندی احساسات یک موضوع پرکاربرد در دهه گذشته و پل ارتباطی بین ماشین و انسان است، درک احساس کاربران برای کامپیوتر به عنوان یک سیستم رابط با مغز ضروری است. [۱-۲]  
راه های زیادی برای تشخیص احساس وجود دارد مانند حالت چهره و امواج مغزی، با این حال، برای برخی از افراد مانند بیماران اوتیسم تشخیص احساس وجود دارد مانند حالت چهره بسیار دشوار است. سیگنال مغزی یک راه حل جایگزین برای دسترسی به احساسات انسانی است، که می توان آن را از روش های تهاجمی<sup>۶</sup> و غیرتهاجمی<sup>۷</sup> بدست آورد. یک سیستم رابط بین مغز و کامپیوتر از نوع تهاجمی با قرار دادن الکترودها بر روی سطح بی حفاظ مغز با استفاده از عمل جراحی و با ایجاد یک برش در جمجمه که این راه برای اغلب انسان ها غیر قابل قبول است. [۳]

<sup>1</sup> Electroencephalography

<sup>2</sup> BCI or Brain Computer Interface

<sup>3</sup> Deep Learning

<sup>4</sup> Feature

<sup>5</sup> Classification

<sup>6</sup> Invasive

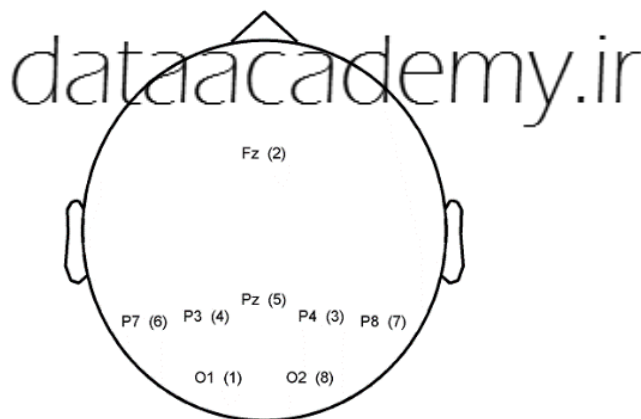
<sup>7</sup> Non-Invasive

راه حل غیرتهاجمی، راه مطلوب و مناسب برای جمع آوری سیگنال مغز شامل انسفالوگرافی مغناطیسی<sup>۱</sup> (MEG) و تصویرسازی تشدید مغناطیسی کارکردی<sup>۲</sup> (fMRI) و الکتروانسفالوگرافی<sup>۳</sup> (EEG) می باشد. به خصوص الکتروانسفالوگرافی که در مقایسه با روش های دیگر محاسناتی چون کم هزینه بودن و سرعت را دارد. ظهور هدست بی سیم الکتروانسفالوگرام باعث شده که کاربران به راحتی قادر به گرفتن اطلاعات از پتانسیل الکتریکی از طریق الکتروود قرار داده شده بر روی پوست سر می سازد.

سیگنال های مغزی را می توان در بسیاری از برنامه های کاربردی علاوه بر کاربردهای مبتنی بر اهداف پزشکی استفاده کرد، مانند بازی ها، مراقبت های بهداشتی، سیستم های سرگرمی. از منظر بهداشت و درمان، برای افراد معلول تسهیل در تنظیم صندلی چرخدارشان با شناسایی سیگنال های مغزی و با یادگیری الگوهای خود نقش دارد، این ایده را می توان برای افراد عادی برای راندن اتومبیل و یا جابه جایی مکان نما (کر سر موس) توسعه داد.

همانگونه که برای افراد اوتیسم برقراری ارتباط از طریق گفتگو و ظاهر دشوار است و این درحالی است که حالت عاطفی این بیماران نقش مهمی در طول درمان و یا ادامه تحصیل آنها دارد. سیگنال های مغزی الگوهای بخصوصی برای هر حالت احساسی از قبیل هیپنوتیز، انگیختگی، ورزش و مراقبه نشان می دهند.

محل قرار گرفتن الکتروودها بر روی سر برای به دست آوردن سیگنال های مغزی در شکل ۱. نشان داده شده است. پس از به دست آوردن سیگنال های مغزی پیش پردازش سیگنال ها اولین مرحله از تجزیه و تحلیل سیگنال است که صورت می گیرد، که شامل حذف نویز، متوسط گیری از سیگنال، آستانه خروجی، بهبود سیگنال و تشخیص لبه می باشد



شکل ۱\_ طریق چیدمان الکتروودها روی سر

حذف نویز از سیگنال مغزی که از تغییر در جریان برق، فعالیت عضلات و یا پلک زدن در طول مدت اخذ سیگنال مغزی می باشد.

استخراج ویژگی همانند کاهش زمان معمولاً نقش مهمی در بالا بردن عملکرد طبقه بند بازی می کند. باندهای فرکانس فاکتور مهمی است که با توجه به اثربخشی اش مطرح می شود، تغییر سیگنال در حوزه زمان یکی دیگر از ویژگی های مهم تجزیه و تحلیل سیگنال های مغزی است با توجه به این موضوع باید ویژگی های حوزه زمان-

1 Magnetoencephalography (MEG)  
2 Functional Magnetic Resonance Imaging (fMRI)  
3 Electroencephalography (EEG)  
4 Edge Detection

فرکانس<sup>۱</sup> را مورد بررسی قرار دهیم. تبدیل فوریه زمان کوتاه (STFT)<sup>۲</sup> روش مرسوم استخراج ویژگی در حوزه زمان فرکانس است. با این حال زمان محاسباتی بالا در سیستم های بی درنگ<sup>۳</sup> مشکل ایجاد می کند که یکی از راه حل های جایگزین پارامترهای جورت<sup>۴</sup> (شامل توصیف گرهای فعالیت<sup>۵</sup> شریک<sup>۶</sup> پیچیدگی<sup>۷</sup> برای محاسبات ساده استفاده می شود [۸-۶]

الگوریتم های یادگیری ماشین متفاوتی برای تشخیص احساسات از سیگنال EEG به کار گرفته شده است، از جمله K- نزدیکترین همسایه (KNN) [۹]، رگرسیون درخت<sup>۸</sup> (RT) [۱۰]، شبکه بیزین (BNT) [۱۱]، ماشین بردار پشتیبانی<sup>۹</sup> (SVM) [۱۲] و شبکه های عصبی مصنوعی (ANN) [۱۳]. اینها الگوریتم هستند که در تشخیص احساسات به موفقیت رسیده اند. با این حال، با توجه به وابستگی به موضوع احساسات به اندازه کافی از نظر دقت عملکرد بالایی ندارند.

در این مقاله ما به الگوریتم یادگیری عمیق به همراه یادگیری ویژگی ها و طبقه بندی احساسات از سیگنال EEG می پردازیم و تفاوت های آن نسبت به روش های مرسوم، اعمال یادگیری عمیق بر روی سیگنال خام بدون استخراج ویژگی صریح و به صورت غیردستی می باشد.

از آنجا که سیگنال EEG وابسته به شخص است، برای یادگیری مدل احساس بهتر است از شخص سالم استفاده نماید. الگوریتم یادگیری عمیق [۱۴] یک راه حل با روش پیش-آموزش با استفاده از ۳ لایه ماشین بولتزمن محدود (RBMs) فراهم می کند، که امروزه به صورت گسترده ای در نرم افزارهای کاربردی مورد استفاده قرار می گیرد. [۲۱]

بنابراین با استفاده از سیکل های همه اشخاص برای پیش-آموزش در شبکه عمیق و استفاده از پس انتشار در شبکه می توانیم به تنظیم مناسب فرد به فرد برسیم. در ادامه، این مقاله به شرح زیر سازماندهی شده است. (بخش ۲) تشخیص احساسات از سیگنال EEG بر اساس یادگیری عمیق. (بخش ۳) الگوریتمی برای مجموعه داده EEG ما، و آزمایش ارائه نتایج. و در نهایت، در (بخش ۴) نتیجه گیری را داریم.

## ۲- تشخیص احساسات بر اساس یادگیری عمیق

روش پس انتشار سنتی برای یادگیری یک معماری عمیق از مسایل بهینه محلی ضعیف و همچنین زمان یادگیری طولانی رنج می برد. همچنین مجموعه آموزشی برچسب زده شده لازم برای پس انتشار که در تجزیه و تحلیل EEG با توجه به وابستگی به شخص کافی نیستند.

- 
- 1 time-frequency
  - 2 short time Fourier transform (STFT)
  - 3 Real-time
  - 4 Hjorth parameter
  - 5 Activity
  - 6 Mobility
  - 7 Complexity
  - 8 K-Nearest Neighbor (KNN)
  - 9 Regression Tree (RT)
  - 1 Bayesian Network (BNT)
  - 1 Support Vector Machine (SVM)
  - 1 Artificial Neural Networks (ANN)

روش یادگیری عمیق برای مقابله با تمام این مشکلات یک راه حل فراهم می کند که ما را قادر به استفاده از داده های بدون برچسب برای مقداردهی اولیه به شبکه عمیق می کند. معماری شبکه عمیق در شکل ۲. نشان داده شده است.

سیگنال های EEG از ۱۴ کانال به یک بردار و به سه لایه از RBMs خورانده شدن، در ادامه توسط لایه خارجی با برچسب احساسات. سه لایه از DBMS ها برای اولین بار پیش یادگیری با استفاده از دوره نامشخص برچسب ها و افراد است. پس انتشار برای تنظیم مدل های عمیق شخص خاص توسط داده با برچسب استفاده می شود.



شکل ۲- معماری یادگیری عمیق با سه لایه از RBM

داده های بدون برچسب راحت تر از داده های برچسب دار به دست می آیند ، بنابراین، ما با استفاده از داده های بدون برچسب برای پیش-آموزش معماری عمیق، برای به دست آوردن وزن اولیه استفاده می کنیم. از طریق این وزن اولیه است که به یک راه حل خوب نزدیک می شویم و به آسانی به یک راه حل بهینه دست می یابد. ماشین بولتزمن محدود یک روش پیش-آموزشی موثر که یک شبکه دو لایه با پیکسل های باینری و تصادفی را به عنوان واحدها پیشنهاد می کند. این دو لایه از پیکسل واحد "قابل مشاهده" و واحد "پنهان" است که با استفاده از اتصالات وزن داده شده متقارن به هم متصل هستند، مدل RBM می تواند به عنوان یک مدل انرژی ارائه شود.

$$E(v, h) = \sum_{i \in \text{visible}} b_i v_i - \sum_{j \in \text{hidden}} b_j h_j - \sum_{i,j} v_i h_j w_{ij} \quad (1)$$

که در آن  $v_i$  و  $h_j$  دارای ارزش باینری ۱ و ۰ هستند،  $b$  و  $w$  به آنها وابسته هستند، و  $w_{ij}$  وزن آنها در ارتباطات است. احتمال این که یک تصویر با توجه به این انرژی امکان پذیر است اختصاص داده است. با توجه به تصویر آموزش، ما به تناوب محاسبه احتمال دولت باینری  $v_i$  و واحدهای پنهان  $h_j$  از فرمول ۱ تنظیم شود به شرح زیر است:

$$p(h_i = 1|v) = \sigma(b_j + \sum_i v_i w_{ij}) \quad (2)$$

$$p(v_j = 1|h) = \sigma(b_i + \sum_j h_j w_{ij}) \quad (3)$$

با به روز رسانی مراحل واحدهای پنهان و بازسازی واحدهای قابل مشاهده است ما میتوانیم تغییر وزن ها را به دست آوریم.

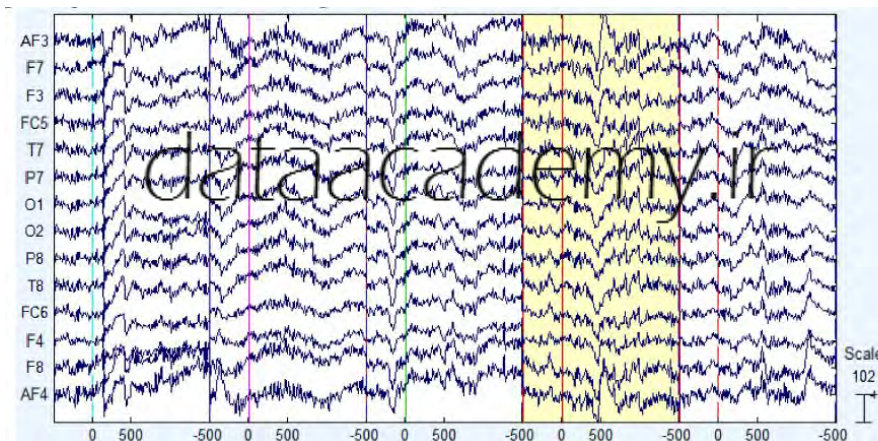
$$\Delta w_{ij} = \varepsilon (\langle v_i h_j \rangle_{data} - \langle v_i h_j \rangle_{recon}) \quad (4)$$

که در آن E نرخ یادگیری است،  $\langle v_i h_j \rangle_{data}$  کسری از ضرب واحد قابل مشاهده و پنهان است که توسط داده ها بدست آمده اند، در حالی که  $\langle v_i h_j \rangle_{recon}$  بازسازی کسر توسط بازسازی تصاویر است.


### ۳- روش و نتایج

#### ۱-۳ پیش پردازش

برای پردازش سیگنالهای EEG از EEGLAB استفاده می کنیم که یک پلت فرم متن باز شده است که توسط آزمایشگاه SCCM ارائه شده است [۱۵]. EEGLAB شامل مجموعه ای از توابع برای کانال های EEG و مدیریت دوره و تجسم است. همانطور که پیش پردازش، حذف نویز [۱۶]، فیلتر [۱۷]، انتخاب دوره، و متوسط گیری سیگنال برای سیگنال های EEG انجام می شود.



شکل-۳ (الف) سیگنال EEG قبل از حذف آرتیفکت پلک زدن

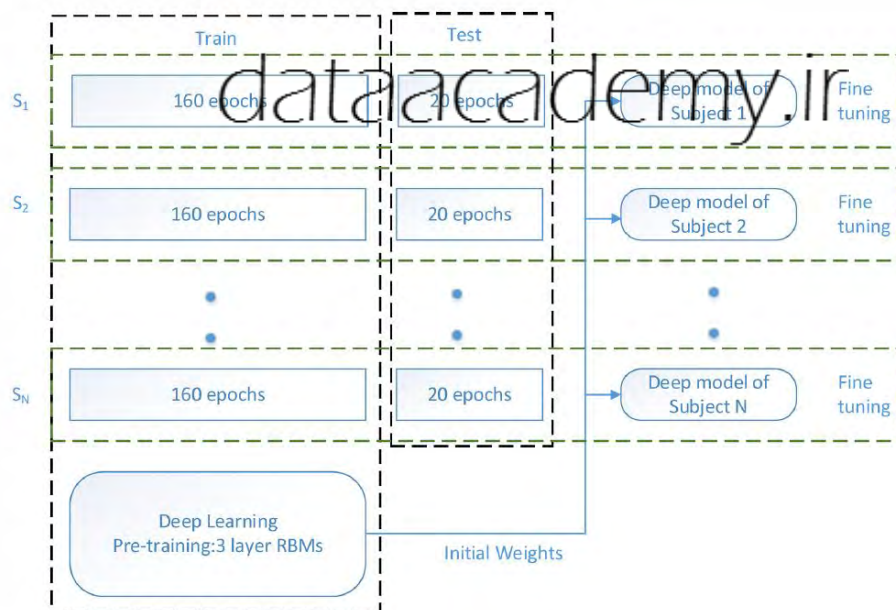


شکل-۳ (ب) سیگنال EEG بعد از حذف آرتیفکت پلک زدن

۱۴ کانال از سیگنال EEG جمع آوری شده از دستگاه هدست EEG وجود دارد [۱۸]. شکل ۳. ۱۴ کانال و سیگنال های مربوطه که در آن است را نشان می دهد [۱۹]، ۳ (الف) نشان دهنده آرتیفکت توسط پلک زدن چشم از طریق FP1 FP2 قبل از حذف آرتیفکت، که با سایه زرد مشخص شده اند. ۳ (ب) بعد از حذف آرتیفکت، اثر پلک زدن چشم است که با سایه زرد نشان داده است.


### ۲-۳ طبقه بندی احساسات

پس از اینکه پیش پردازش تکمیل شد، سیگنال های EEG تمیز، بدون استخراج ویژگی به شبکه عمیق خوانده شدند. پایگاه داده ایی که در این مقاله مورد استفاده قرار گرفته است از ۲۱ نفر و ۱۸۰ اپک با ۱۹۲ بعد برای هر فرد جمع آوری شده است. چهار احساس: شادی، آرامش، غم، و ترس در آزمایش ها تعریف شده است که برای هر یک از احساسات، ۴۵ اپک برای هر فرد جمع آوری شد. همانطور که قبلا ذکر شد، طبقه بندی احساسات وابسته به فرد است بنابراین، برای هر فرد اپک ها را به اپک های آموزش واپک های تست تقسیم کرده است..  
 با توجه به معماری یادگیری عمیق که متشکل از پیش-یادگیری و تنظیم است، ما با استفاده از اپک تمام افراد برای پیش-یادگیری و اپک های خاص فرد برای تنظیم مدل عمیق برای هر فرد در شکل ۴ نشان داده شده است.



شکل ۴- روش آزمایش طبقه بندی بر اساس احساسات مبتنی بر یادگیری عمیق

پیش-یادگیری یک بار برای تمام افراد انجام می شود در حالیکه در مدل های عمیق برای هر فرد بر اساس وزن اولیه پیش-یادگیری تنظیم می شود که در شکل ۴. نشان داده شده است. دقت تشخیص احساسات افراد در شکل ۵. نشان داده شده است این شکل تایید می کند که تشخیص احساسات وابسته به فرد است دقت از فرد به فرد دیگر متفاوت است و واریانس بالایی از دقت نشان داده شده است.



شکل ۵- دقت تشخیص احساسات از موضوعات مختلف

همچنین از اعتبار سنجی متقابل<sup>۱</sup> در این مقاله استفاده شده است، به طور تصادفی ۱۸۰ اپک از هر فرد را به ۱۶۰ اپک مجموعه آموزش و ۲۰ اپک مجموعه تست تقسیم می کنند. این فرایند برای به دست آوردن عملکرد بهتر متوسط ده بار تکرار می شود. جدول ۱. دقت متوسط تشخیص احساسات از سه الگوریتم مقایسه (SVM، KNN، و ANN) و سه پیاده سازی یادگیری عمیق را نشان می دهد:

- (۱) فرد متحد: از ۱۱ نفر برای یادگیری ، و ۱۰ فرد برای تست در این پیاده سازی استفاده شده است.
- (۲) انتخاب کانال: اشاره به این دارد که هرکانال از نظر دقت تشخیص احساسات اثر همانند ندارند. شش کانال به عنوان سیگنال خام، که کانال های F1، F2، F3، F4، C1، C2، C3، C4، FP1، FP2، FP3، FP4 و انتخاب شده.
- (۳) وابستگی به فرد : در شکل ۲. پیاده سازی شده است، مدل عمیق فرد به فرد تنظیم و تست شده است.

جدول ۱. نشان می دهد که پیاده سازی بدون در نظر گرفتن بستگی به فرد کارایی کمی دارد با توجه به وابستگی به فرد، در حالی که پیاده سازی انتخاب کانال دارای عملکرد قابل مقایسه با موضوع بستگی فرد دارد و حتی کارایی کانال ها بسیار کاهش می یابد. همانطور که برای SVM، KNN، و ANN، استفاده از پروتکل بستگی به فرد است که الگوریتم آموزش و تست توسط افراد جدا شده است. در این روش دوره ای از افراد غیردرگیر با دیگر افراد آموزش داده شده، و نداشتن همکاری با فرد صحیح هستند . بنابراین، پیاده سازی بستگی فرد دقت تشخیص بهتر در مقایسه با الگوریتم مرسوم به دست می آورد ، در حالی که نیاز به بهبود بیشتر وجود دارد.

جدول ۱- دقت تشخیص احساسات پیاده سازی های مختلف یادگیری عمیق و دیگر الگوریتم ها

الگوریتم	دقت بر حسب درصد %
KNN	۵۱/۳
SVM	۶۰/۸
ANN	۶۰
عدم بستگی به فرد	۲۸/۶
انتخاب کانال	۵۷/۲
بستگی به فرد	۶۸/۴

1 Goss-validation

#### ۴- نتیجه گیری

یک معماری یادگیری عمیق برای یادگیری و طبقه بندی احساسات از سیگنال EEG ارائه شده است. تفاوت آن با روش های مرسوم، به کار بردن یادگیری عمیق در سیگنال خام و بدون استخراج دستی ویژگی هاست. الگوریتم یادگیری عمیق ما یک راه حل با یک پیش-یادگیری با استفاده از سه لایه از ماشین بولترمن محدود (RBMs) فراهم می کند. بنابراین، می توان از دوره تمام افراد برای پیش-یادگیری شبکه عمیق و استفاده از پس انتشار در شبکه با تنظیم فرد به فرد استفاده کرد. نتایج آزمایش تایید می کند تشخیص احساسات از سیگنال EEG وابسته به فرد است، و موضوع یادگیری عمیق بسته به فرد به دقت تشخیص بهتری از الگوریتم های معمولی دست یافته است. همچنین با انتخاب کانال مناسب می توانیم با استخراج ویژگیهای متمایز کننده بهتر برای طبقه بندی سیگنالها رسید.

#### مراجع:

1. L. Mayaud, M. Congedo, A. van Laghenhove et al., (2013.), "A comparison of recording modalities of P300 Event Related Potentials (ERP) for Brain-Computer Interface (BCI) paradigm, " Clinical Neurophysiology, vol. 43, no. 4, pp. 217-227
2. J. L. S. Blasco, E. I'a-nez, A. ' Ubeda, and J. M. Azor'm,( 2012), "Visual evoked potential-based brain-machine interface applications to assist disabled people, " Expert Systems with Applications, vol. 39, no. 9, pp. 7908- 7918D.
3. J. DellaBadia Jr., et al. (2002), "Assessment and cost comparison of sleep-deprived EEG, MRI and PET in the prediction of surgical treatment for epilepsy, " Seizure, vol. 11, no. 5, pp. 303-309.
4. M. R. N. Kousarrizi, A. A. Ghanbari, M. Teshnehlab, M. Aliyari, and A. Gharaviri,(2009) "Feature extraction and classification of EEG signals using wavelet transform, SVM and artificial neural networks for brain computer interfaces, " in Proceedings of the International Joint Conference on Bioinformatics. Systems Biology and Intelligent Computing, pp. 352-355.
5. K. M. Kemal, et al,(2005), "Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application, " Computers in Biology and Medicine, vol. 35, no. 7, pp. 603-616.
6. H. Bo, (1997), "EEG analysis based on time domain properties, " Electroencephalography and Clinical Neurophysiology, vol. 29, no. 3, pp. 306-310.
7. V. Carmen, et ai, (2009), "Time domain parameters as a feature for EEG-based brain computer interfaces, " Neural Networks, vol. 22, no. 9, pp. 1313-1319.
8. S. H. Oh, Y. R. Lee, H. N. kim, (2014), "A Novel EEG Feature Extraction Method Using Hjorth Parameter, " International Journal of Electronics and Electrical Engineering, vol. 2, no. 2, pp. 106-110..
9. H. Parvin, H. Alizadeh, and B. Minaei-Bidgoli, (2008), "MKNN: Modified k-nearest neighbor, " in Proc. World Congress on Engineering and Computer Science. San Francisco, USA.
10. L. Breiman, (1997) ,"Classification and regression trees.,.
11. Boca Raton, Fla.: Chapman & Hall, (1984). [11]N. Friedman, D. Geiger, and M. Goldszmidt, "Bayesian Network Classifiers, " Machine Learning, vol. 29, no. 2, pp. 131-163.



12. V. N. Vapnik, (1999), "An overview of statistical learning theory, " IEEE Transactions on Neural Networks, vol. 10, no. 5, pp. 988 -999.
13. C. K. ho and M. Sasaki, (2002), "EEG data classification with several mental tasks, " in Proc. IEEE International Conference on Systems. Man and Cybernetics, vol. 6.2002.
14. G. E. Hinton, R. R. Salakhutdinov,(2006), "Reducing the Dimensionality of Data with Neural Networks, " Science, vol. 313, pp. 504-507.
15. Delorme and S. Makeig,(2004), "EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis, " Journal of NeuroscienceMethods, vol. 134, no. 1, pp. 9-21.
16. G. Gomez-Herrero, W. de Clercq, H. Anwar et al., (2006), "Automatic removal of ocular artifacts in the EEG without an EOG reference channel, " in Proceedings of the 7th Nordic Signal Processing Symposium, pp. 130- 133..
17. A. Widmann and E. Schroger,(2012),"Filter effects and filter artifacts in the analysis of electrophysiological data, " Frontiers in Psychology, vol. 3.
18. R. Du, R. M. Mehmood, and H.-J. Lee,(2014) "Alpha Activity during Emotional Experience Revealed by ERSP, " Journal of Internet Technology, vol. 15, pp. 775-782.
19. T. Sohaib, S. Qureshi, J. Hagelback, O. Hilborn, P. Jeric6,(2015) "Evaluating classifiers for Emotion Recognition using EEG, " Foundations of Augmented Cognition, vol. 8027, pp. 492-501, 2013.
20. R. M. Mehmood and H. J. Lee, "Exploration of Prominent Frequency Wave in EEG Signals from Brain Sensors Network, " International Journal of Distributed Sensor Networks.
21. Y. Lv, Y. Duan, W. Kang, Z. Li, F. Y. Wang,(2015), "Traffic Flow Prediction With Big Data: A Deep Learning Approach, " IEEE Transaction on Intelligent Transportation Systems, vol. 16, no. 2, pp. 865-873.