

# Review Pemanfaatan Data Electroencephalogram (EEG) dengan metode Convolution Neural Network

Muchamad Kurniawan<sup>1</sup>, Andy Rachman<sup>2</sup>, Adib Pakarbudi<sup>3</sup>

<sup>1,2</sup>Jurusan Teknik Informatika, Institut Teknologi Adhi Tama Surabaya

<sup>3</sup>Jurusan Sistem Informasi, Institut Teknologi Adhi Tama Surabaya

Email: <sup>1</sup>muchamad.kurniawan@itats.ac.id, <sup>2</sup>andy.rach1910@itats.ac.id, <sup>3</sup>adib@itats.ac.id

**Abstract.** *Electroencephalogram (EEG) is a brain data signal that is captured by sensors. Many studies have used EEG to be used as a decision maker or classifying. What classification has been used most frequently in existing studies over the last 5 years? These are the questions that will be answered in this research. In addition to these questions, another question that will be answered is what is the most popular method used in processing EEG data? The final question in research is the recent development of EEG and CNN research. The results of these answers are the most popular research using the CNN method as a classification method, the application of the field of Human-computer Interfaces*

**Keywords:** *Electroencephalogram, Convolution Neural Network.*

**Abstrak.** *Electroencephalogram (EEG) merupakan data sinyal otak yang ditangkap dengan sensor. Penelitian-penelitian telah banyak menggunakan EEG untuk dimanfaatkan sebagai pengambil keputusan atau mengklasifikasi. Klasifikasi apa yang paling sering digunakan dalam penelitian-penelitian yang telah ada selama 5 tahun terakhir? Pertanyaan tersebut merupakan pertanyaan yang akan dijawab dari penelitian ini. Selain pertanyaan tersebut yang akan dijawab pertanyaan lain adalah metode apa yang paling populer digunakan dalam pengolahan data EEG? pertanyaan terakhir dalam penelitian adalah perkembangan terbaru dari penelitian EEG dan CNN. Hasil dari jawaban-jawaban tersebut adalah penelitian terpopuler menggunakan metode CNN sebagai metode klasifikasi, penerapan di bidang area Human-computer Interfaces.*

**Kata Kunci:** *Electroencephalogram, Convolution Neural Network.*

## 1. Pendahuluan

Electroencephalogram (EEG) merupakan aktifitas otak yang direkam berupa sinyal digital (Abiri et al., 2019). EEG telah banyak digunakan dalam berbagai bidang. Penelitian tentang EEG digunakan untuk mendeteksi gangguan Alzheimer (Vecchio et al., 2020), gangguan Epilepsi (Thanaraj et al., 2020), Coronavirus (Pilato et al., 2020), Parkinson (Bočková & Rektor, 2019) dan lain-lain. EEG juga sering diteliti untuk pendeteksian emosi ataupun kelainan seseorang (akashina T., Yanagi M., Yamariku Y., Hirayama Y., Horie R., 2019) (Li et al., 2020) (Zeng, H.; Wu, Z.; Zhang, J.; Yang, C.; Zhang, H.; Dai, G.; Kong, 2019).

Banyak metode klasifikasi yang pernah digunakan pada data EEG seperti metode k-Nearest Neighbor (k-NN / KNN) untuk mengklasifikasi data EEG. Choubey dan Pendey (Choubey & Pandey, 2021) mengkombinasikan data statistik dari EEG untuk mendeteksi penyakit epilepsi dari EEG menggunakan metode klasifikasi KNN dan ANN yang sebagai benchmark. Penelitian tahun 2020 (Wang et al., 2020) menggunakan fitur ekstraksi Fourier transform (DFT) dan modifikasi dari KNN yang disebut A Weighted K-nearest Neighbor Classifier based on Bray Curtis distance (WBCKNN).

Metode Support Vector Machine juga dilakukan untuk pendeteksian mental stress EEG tahun 2018 (Al-shargie et al., 2018) menggunakan 18 orang untuk validasi penelitian. Metode SVM yang digunakan merupakan modifikasi SVM menggunakan Error-correction output code. Penelitian tahun 2019 menambahkan multilevel assessment pada proses validasi penelitian (Al-Shargie, 2019). SVM untuk mendeteksi kelainan autisme dilaporkan tahun 2020 (Kang et al., 2020), pendeteksian konsentrasi manusia diteliti oleh (Purnamasari & Junika, 2019), dan pendeteksian level stress manusia dilaporkan pada tahun 2017 (Gaikwad & Paithane, 2017).

Artificial Neural Network (ANN) merupakan metode klasifikasi yang sering digunakan untuk pengolahan data EEG. Penelitian pendeteksian emosi manusia pernah dilaporkan menggunakan metode ANN dengan modifikasi Long Short Term Memory (LSTM) (Alhagry et al., 2017). EEG dihasilkan dari sensor motor yang ditempelkan pada kepala manusia, untuk mencari efisiensi jumlah motor EEG

yang optimal metode ANN digunakan untuk mendapatkan hal tersebut (Maksimenko et al., 2018). Kelainan epilepsi pernah dilaporkan telah berhasil diklasifikasi dengan metode Neural Network pada tahun 2020 (George et al., 2020). Kombinasi metode ANN dengan metode optimasi metaheuristic Lion optimization dan Geneteic algorithm pernah juga dilaporkan (Kose, 2018) (Saddam et al., 2017).

Pada paper review ini diklasifikasikan penelitian tentang pemanfaatan sensor EEG untuk klasifikasi mental manusia meliputi klasifikasi epilepsi, emosi, tingkat stress, maupun penyakit yang lain. Paper review ini juga tentang perkembangan penelitian EEG dengan metode Convolution Neural Network, sehingga dapat mengetahui penelitian yang telah ada dan dapat mengetahui arah atau pola penelitian selanjutnya.

Pertanyaan yang akan dijawab pada penelitian terdapat 3 pertanyaan:

- Penyakit mental apa yang paling sering diteliti dalam 3 tahun terakhir
- Metode apa yang paling sering digunakan dengan memanfaatkan sensor EEG?
- Bagaimana perkembangan penelitian EEG menggunakan CNN 3 tahun terakhir?

Susunan bagian penelitian ini adalah: pendahuluan penelitian, tinjauan Pustaka yang akan menerangkan teori tentang metode-metode terkait, bagian metodologi, hasil, dan kesimpulan penelitian.

## 2. Tinjauan Pustaka


### 2.1 EEG

Aktifitas listrik pada otak manusia dapat diamati dengan menggunakan sebuah alat instrumentasi yaitu Electroencephalography (EEG). Klasifikasi dari sinyal EEG terhadap perubahan variable tertentu dapat menerangkan fungsi kerja dari otak dan menangkap perubahan aktifitas otak terhadap variable yang diberikan. Sinyal EEG dapat dipengaruhi oleh beberapa variable diantaranya kondisi mental, kesehatan, aktifitas dari pasien, lingkungan perekaman, gangguan atau rangsangan dan usia dari pasien [25]. Klasifikasi sinyal EEG dapat dilakukan dengan algoritma deep learning yang memiliki beberapa arsitektur dan salah satunya yaitu deep learning neural networks.

Deteksi sinyal EEG telah diaplikasikan untuk permasalahan tertentu seperti penelitian (Zhang et al., 2018). Brain Computer Interface (BCI) berbasis EEG dapat memberikan kesempatan kepada setiap orang untuk berinteraksi dengan suatu perangkat dengan menafsirkan sinyal EEG otak. Pendekatan yang diusulkan menggunakan Convolution Neural Network (CNN) untuk mempelajari fitur sinyal EEG sehingga dari sinyal EEG yang dideteksi dapat diterjemahkan ke dalam bentuk teks. Deteksi sinyal EEG dengan memanfaatkan CNN juga dapat diaplikasikan untuk deteksi kebohongan (Baghel et al., 2020).

### 2.2 CNN

Salah satu algoritma *Deep Learning* adalah *Convolutional Neural Network* (CNN) berfungsi mengolah data citra dua dimensi. CNN termasuk metode *supervised learning* dan sering digunakan untuk mengenali benda atau pemandangan serta melakukan deteksi dan segmentasi objek. CNN menggabungkan tiga pokok arsitektur, yaitu *local receptive fields*, *Shared weight* yang berupa *filter*, dan *spatial subsampling* yang berupa *Pooling*. Konvolusi atau yang biasa disebut dengan *Convolution* merupakan matriks yang berfungsi untuk melakukan *filter*. Arsitektur yang dimiliki oleh *Convolutional Neural Network* (CNN) sebagai berikut seperti Gambar 1.



Gambar 1. Algoritma Convolution Network

## Convolution Layer

*Convolutional Layer* merupakan layer pertama yang menerima *input* gambar langsung pada arsitektur. Operasi pada layer ini melakukan operasi kombinasi linier filter terhadap daerah local. Perhitungan dimensi *Convolution Layer* dapat menggunakan formula berikut:

$$W_2 = (W_1 - F + 2P)/S + 1 \quad (1)$$

$$H_2 = (H_1 - F + 2P)/S + 1 \quad (2)$$


$$D_2 = K \quad (3)$$

Dimana K, F, S, P, D, W, dan H adalah jumlah filter yang digunakan, ukuran spasial dari filter (lebar/tinggi), stride, atau besar pergeseran filter dalam konvolusi, padding & jumlah penambahan nol pada gambar, dimensi, lebar pixel citra, dan tinggi pixel citra.

Secara umum operasi konvolusi dapat ditulis dengan rumus berikut.

$$s(t) = (x * w)(t) \quad (4)$$

Pada fungsi  $s(t)$  menghasilkan *output* tunggal yaitu *Feature Map*, argumen pertama berupa *input* yang merupakan  $x$  dan *argument* kedua yang merupakan  $w$  sebagai kernel atau *filter*. Jika melihat *input* sebagai citra dua dimensi, maka  $(t)$  bisa diasumsikan sebagai sebuah piksel dan menggantinya dengan  $i$  dan  $j$ . Gambar 2, dibawah ini menunjukkan cara kerja dari *Convolution Layer*.



Gambar 2. Convolution Layer

## Stride

*Stride* adalah parameter yang menentukan berapa jumlah pergeseran *filter* (DEWI, 2018). Jika nilai *stride* adalah satu, maka *feature map* akan bergeser sebanyak 1 *pixel* secara *horizontal* lalu *vertical*. Semakin kecil *stride* yang digunakan, maka semakin detail informasi yang didapatkan dari sebuah *input*, namun membutuhkan komputasi lebih jika dibandingkan dengan *stride* yang besar.

## Padding

*Padding* merupakan salah satu parameter yang menentukan jumlah piksel yang berisi nilai nol dan untuk ditambahkan di setiap sisi pada citra *input* sehingga mengatur dimensi *output* agar tetap sama seperti dimensi *input* sehingga dapat dilakukan *ekstraksi feature* yang lebih mendalam.

## Activation Function


*Activation function* merupakan sebuah node yang ditambahkan di akhir *output* dari setiap jaringan syaraf (DEWI, 2018). Pada arsitektur CNN, fungsi aktivasi terletak pada perhitungan akhir keluaran *feature map* untuk menghasilkan suatu pola fitur. Fungsi aktivasi yang sering digunakan yaitu fungsi sigmoid, tanh, *Rectified Linier Unit* (ReLU), Leaky ReLU (LReLU) dan *Parametric ReLU*. Secara umum operasi ReLU (*Rectified Linier Unit*) dapat ditulis dengan rumus berikut.

$$f(x) = \max(0, x) \quad (5)$$

$$f(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} \quad (6)$$

## Pooling Layer

*Pooling Layer* menggunakan fungsi *feature map* sebagai masukan dan mengolahnya dengan berbagai macam operasi statistik berdasarkan nilai piksel terdekat. *Pooling layer* disisipkan secara teratur setelah beberapa *convolution layer* dan dapat secara progresif mengurangi ukuran *volume output* pada *feature map* sehingga jumlah parameter dan perhitungan di jaringan berkurang, dan mempercepat komputasi karena parameter yang harus diupdate semakin sedikit serta untuk mengatasi *overfitting*. *Pooling layer* digunakan untuk mengambil nilai maksimal (*max-pooling*) dari bagian-bagian piksel pada citra. Cara kerja *Max pooling* adalah membagi *output* dari hasil *convolution layer* menjadi beberapa *grid* kecil lalu mengambil nilai maksimal dari setiap *grid* seperti Gambar 3.



Gambar 3. Pooling Layer

Kotak yang berwarna merah, hijau, kuning dan biru pada sisi kiri merupakan kelompok kotak yang akan dipilih nilai maksimumnya. Sehingga hasil dari proses tersebut dapat dilihat pada kumpulan kotak disebelah kanannya. Proses tersebut memastikan fitur yang didapatkan akan sama meskipun objek citra mengalami translasi (pergeseran). Untuk formula dari Pooling Layer adalah sebagai berikut:

$$W_2 = (W_1 - F) / S + 1 \quad (7)$$

$$H_2 = (H_1 - F) / S + 1 \quad (8)$$

$$D_2 = D_1 \quad (9)$$

Variabel W, H, F, S, dan D adalah lebar piksel citra, tinggi piksel citra, ukuran spasial filter (lebar/tinggi), *stride* atau besar pergeseran filter dalam konvolusi, dan dimensi.

#### Full Connected Layer

Hasil dari *convolution layer* berbentuk *multidimensional array*, dan melalui proses *flatten* untuk mengubah menjadi sebuah vektor agar bisa digunakan sebagai input dari *fully-connected layer*. Lapisan *Fully-Connected* adalah lapisan di mana semua neuron aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya seperti halnya jaringan saraf tiruan biasa.

### 3. Metode Penelitian

Untuk menjawab pertanyaan pada pendahuluan maka dibutuhkan metodologi untuk setiap pertanyaan. Maka setiap metodologi akan mempunyai metodologi berbeda.

**Pertanyaan pertama: Penyakit mental apa yang paling sering diteliti dalam 3 tahun terakhir?**

**Pertanyaan kedua: metode apa yang paling sering digunakan dalam 3 tahun terakhir untuk mengolah data EEG?**

Untuk menjawab pertanyaan pertama dan kedua metodologi yang akan digunakan adalah dengan mengumpulkan penelitian dari search engine google (scholar.google.com). paper yang akan dikumpulkan sebanyak 30 paper dari setiap query yang dimasukkan. Query yang dimasukkan: Electroencephalography classification, Electroencephalography identification, Electroencephalography Recognition. Total dari penelitian yang digunakan adalah 150 penelitian. Jurnal yang akan digunakan adalah jurnal dan seminar internasional (berbahasa inggris).

**Pertanyaan ketiga: Bagaimana perkembangan penelitian EEG menggunakan CNN?**

untuk menjawab pertanyaan terakhir ini metodologi penelitian yang kami gunakan adalah dengan menelusuri paper-paper yang terbaru dari CNN dengan memanfaatkan data EEG.


### 4. Hasil Dan Kesimpulan

#### 4.1 Area paling banyak yang digunakan pada data EEG

Jawaban pertanyaan dari area pemanfaatan data EEG yang paling sering digunakan adalah Human-computer Interface. Human-computer Interface adalah merupakan gabungan dari komputer dan manusia. Penelitian-penelitian tentang HCI terdapat jumlah 26 penelitian, untuk lebih jelasnya dapat dilihat pada tabel 1. Pemanfaatan data EEG yang lain adalah pada pengolahan data EEG itu sendiri, pada penelitian ini tidak terdapat pemanfaatan dari data yang diperoleh. Pengolahan data EEG meliputi pengolahan preproceasing data EEG, ekstraksi fitur data EEG, dan bagaimana mendapatkan hasil terbaik dari classification data EEG. pemanfaatan area yang terbanyak selanjutnya adalah tentang penangkapan emotional manusia dari data EEG. Selanjutnya terdapat pendeteksian Epilepsy, dan selebihnya adalah kelainan penyakit mental yang lain.

**Tabel 1. Area Pemanfaatan data EEG**


<i>Area Pemanfaatan EEG</i>	<i>Jumlah Penelitian</i>
Human-Computer Interfaces (HCI)	26
EEG	24
Emotion	19
Epilepsy	10
Other Mental Disorder	11

**Gambar 4. Area Pemanfaatan data EEG**

#### 4.2 Metode yang paling sering digunakan pada EEG

Hasil jawaban dari pertanyaan kedua dilihat pada Gambar 5. Metode yang paling sering digunakan atau paling populer untuk mengolah data EEG adalah CNN. Sebanyak 40 penelitian yang mencantumkan metode deep learning atau CNN. Artificial Neural Network merupakan metode yang paling sering digunakan ke-2 setelah CNN. Sedangkan untuk metode-metode yang lainnya dapat dilihat pada Tabel 1. Sedangkan yang ada pada other classifier adalah metode Linear discriminant analysis, Wavelete, Logistic Regression, Entropy Analysis, Naïve Bayes Classification, Decision Tree.


Dari hasil yang diperoleh dari pencarian metode yang paling sering digunakan, metode CNN merupakan metode yang paling baru dari semua metode yang telah disebutkan di atas. Penelitian yang menggunakan metode CNN sebagai classifier merupakan perkembangan dari metode CNN. Hal ini menunjukkan metode CNN yang merupakan metode yang paling baru, tetapi masih terus dikembangkan dan masih banyak peluang kedepanya.

**Gambar 5. Metode Classifier****Tabel 2. Hasil Metode Terbanyak Digunakan**

<i>Classifier</i>	<i>Jumlah Penelitian</i>
<i>CNN</i>	40
<i>ANN</i>	13
<i>SVM</i>	12
<i>KNN</i>	6
<i>other classifiers</i>	19

### 4.3 Penelitian CNN dengan memanfaatkan data EEG

(Ma et al., 2021) adalah penelitian tentang pengenalan kelainan epilepsy. Metodologi penelitian yang digunakan dapat dilihat pada Gambar 6. Dataset yang digunakan ada 2 dataset, private dataset dan public dataset. Kedua data tersebut digunakan untuk membuat pemodelan metode CNN. Untuk mengevaluasi model CNN maka digunakan 10-fold Cross validation.



**Gambar 6. Metodologi Penelitian (Ma et al., 2021)**

Metode yang digunakan pemodelan adalah kombinasi dari Recurrent Neurat Network and 1-D CNN dan untuk mengoptimalkan ekstrasi fitur yang digunakan adalah Independent recurrent neural network (indRNN). Untuk mendapatkan hasil yang komperhensive pada penelitian ini menggunakan dua jenis dataset class target data, 2 class dan 3 class. setiap dataset metode RCNN yang diusulkan akan dilakukan benchmark dengan 4 metode yang lain: LSSTM, 1DCNN, INDRNN, dan RESNET. Hasil yang diperoleh dari metode RCNN mendapatkan hasil terbaik dari percobaan. Hasil terbaik dari 2 class adalah akurasi mencapai 100% dan akurasi mendapatkan nilai akurasi 92.11%.

### Integrated CWT-CNN for Epilepsy Detection Using Multiclass EEG Dataset (Naseem et al., 2021)

Pada penilitian ini juga menggunakan data EEG untuk mengklasifikasi kelainan epilepsy. Datset yang diugnakan berasal dari dataset public / data secondary UCI (Machine Learning Repository). Metodeologi yang digunakan adalah dengan ekstrasi data menggunakan metode *Continuous Transform Transform* (CWT) dan CNN. Untuk memvalidasi metodologi yang digunakan adalah k-fold crossvalidation dengan nilai k=10. Nilai epoch (iterasi) yang digunakan untuk metode yang diusulkan lebih rendah dibandingkan dengan metode pendahulunya.

Metode benchmark yang digunakan adalah 4 metode yang lain GoogleNet, AlexNet, VGG16, Mao et al (2020). Hasil yang diperoleh dapat dilihat pada Tabel 3. Baik hasil training dan testing metode yang diusulkan lebih bagus dari metode-metode yang digunakan benchmark.,

**Tabel 3. Hasil Penelitian (Naseem et al., 2021)**

<i>Model</i>	<i>Accuracy (%)</i>		<i>Loss (%)</i>		<i>Test Accuracy (%)</i>	<i>Time (m)</i>
	<i>Train</i>	<i>Validation</i>	<i>Trrian</i>	<i>Validation</i>		
GoogleNet	81.29	77.97	42.34	47.72	77.97	448
AlexNet	88.83	72.35	29.45	73.90	71.25	219
VGG16	75.86	74.38	52.91	53.59	74.32	305
Mao et al (2020)	72.49		59.60			820
Our model	90.46	78.84	27.55	53.04	78.84	36

### 5. Kesimpulan

Dari hasil penelitian yang telah dilakukan dapam diperoleh kesimpulan bahwa dataset Electroencephalogram (EEG) dapat dimanfaatkan pada beberapa area penelitian. Area penelitian yang paling banyak digunakan adalah Human-computer Interface atau lebih spesifik kepada Brain-computer interaction yang berarti kita dapat mengkontrol perangkat keras dengan data EEG. pemanfaatan yang lain adalah dapat mendeteksi berbagai kelainan mental manusia seperti Epilepsy, Alzheimer, Parkinson, dan lain-lain. Selain dimanfaatkan dengan area yang lain, penelitian tentang pengolahan data EEG itu sendiri cukup banyak juga diteliti dalam 5 tahun terakhir. Metode yang digunakan untuk mengolah data EEF dengan keyword classification, identification, dan recognition dalam lima tahun terakhir metode Deep Learning atau Convolution Neural Network (CNN) adalah metode yang paling sering digunakan. Banyak penelitian yang telah memodifikasi metode CNN ini untuk memperoleh hasil yang lebih baik. Metode-metode seperti SVM, KNN dan ANN tetap digunakan tetapi sudah mulai menurun lima tahun terakhir ini.

## Referensi

- Abiri, R., Borhani, S., Sellers, E. W., Jiang, Y., & Zhao, X. (2019). A comprehensive review of {EEG}-based brain-computer interface paradigms. *Journal of Neural Engineering*, 16(1), 11001. <https://doi.org/10.1088/1741-2552/aaf12e>
- akashina T., Yanagi M., Yamariku Y., Hirayama Y., Horie R., O. M. (2019). Toward Practical Implementation of an Emotion-Driven Digital Camera Using EEG. *Kawaii Engineering. Springer Series on Cultural Computing. Springer, Singapore*. [https://doi.org/10.1007/978-981-13-7964-2\\_9](https://doi.org/10.1007/978-981-13-7964-2_9)
- Al-Shargie, F. (2019). *Multilevel Assessment of Mental Stress using SVM with ECOC: An EEG Approach*. Li, 1–19. <https://doi.org/10.31224/osf.io/7v9ks>
- Al-shargie, F., Tang, T. B., Badruddin, N., & Kiguchi, M. (2018). Towards multilevel mental stress assessment using SVM with ECOC: an EEG approach. *Medical & Biological Engineering & Computing*, 56(1), 125–136. <https://doi.org/10.1007/s11517-017-1733-8>
- Alhagry, S., Aly, A., & A., R. (2017). Emotion Recognition based on EEG using LSTM Recurrent Neural Network. *International Journal of Advanced Computer Science and Applications*, 8(10), 8–11. <https://doi.org/10.14569/ijacsa.2017.081046>
- Baghel, N., Singh, D., Dutta, M. K., Burget, R., & Myska, V. (2020). Truth Identification from EEG Signal by using Convolution neural network: Lie Detection. *2020 43rd International Conference on Telecommunications and Signal Processing (TSP)*, 550–553. <https://doi.org/10.1109/TSP49548.2020.9163497>
- Bočková, M., & Rektor, I. (2019). Impairment of brain functions in Parkinson's disease reflected by alterations in neural connectivity in EEG studies: A viewpoint. *Clinical Neurophysiology*, 130(2), 239–247. <https://doi.org/https://doi.org/10.1016/j.clinph.2018.11.013>
- Choubey, H., & Pandey, A. (2021). A combination of statistical parameters for the detection of epilepsy and EEG classification using ANN and KNN classifier. *Signal, Image and Video Processing*, 15(3), 475–483. <https://doi.org/10.1007/s11760-020-01767-4>
- DEWI, S. R. (2018). Deep Learning Object Detection Pada Video. *Deep Learning Object Detection Pada Video Menggunakan Tensorflow Dan Convolutional Neural Network*.
- Gaikwad, P., & Paithane, A. N. (2017). Novel approach for stress recognition using EEG signal by SVM classifier. *2017 International Conference on Computing Methodologies and Communication (ICCMC)*, 967–971. <https://doi.org/10.1109/ICCMC.2017.8282611>
- George, S. T., Subathra, M. S. P., Sairamya, N. J., Susmitha, L., & Joel Premkumar, M. (2020). Classification of epileptic EEG signals using PSO based artificial neural network and tunable-Q wavelet transform. *Biocybernetics and Biomedical Engineering*, 40(2), 709–728. <https://doi.org/https://doi.org/10.1016/j.bbe.2020.02.001>
- Kang, J., Han, X., Song, J., Niu, Z., & Li, X. (2020). The identification of children with autism spectrum disorder by SVM approach on EEG and eye-tracking data. *Computers in Biology and Medicine*, 120, 103722. <https://doi.org/https://doi.org/10.1016/j.complbiomed.2020.103722>
- Kim, J., Park, Y., & Chung, W. (2020). Transform based feature construction utilizing magnitude and phase for convolutional neural network in EEG signal classification. *2020 8th International Winter Conference on Brain-Computer Interface (BCI)*, 1–4. <https://doi.org/10.1109/BCI48061.2020.9061635>
- Kose, U. (2018). An Ant-Lion Optimizer-Trained Artificial Neural Network System for Chaotic Electroencephalogram (EEG) Prediction. *Applied Sciences*, 8(9). <https://doi.org/10.3390/app8091613>
- Lee, B., Jeong, J., Shim, K., & Kim, D. (2020). Motor Imagery Classification of Single-Arm Tasks Using Convolutional Neural Network based on Feature Refining. *2020 8th International Winter Conference on Brain-Computer Interface (BCI)*, 1–5. <https://doi.org/10.1109/BCI48061.2020.9061632>
- Lee, H. K., & Choi, Y. (2018). A convolution neural networks scheme for classification of motor imagery EEG based on wavelet time-frequency image. *2018 International Conference on Information Networking (ICOIN)*, 906–909. <https://doi.org/10.1109/ICOIN.2018.8343254>
- Li, J., Qiu, S., Shen, Y., Liu, C., & He, H. (2020). Multisource Transfer Learning for Cross-Subject

- EEG Emotion Recognition. *IEEE Transactions on Cybernetics*, 50(7), 3281–3293. <https://doi.org/10.1109/TCYB.2019.2904052>
- Ma, M., Cheng, Y., Wei, X., Chen, Z., & Zhou, Y. (2021). Research on epileptic EEG recognition based on improved residual networks of 1-D CNN and indRNN. *BMC Medical Informatics and Decision Making*, 21(2), 1–14. <https://doi.org/10.1186/s12911-021-01438-5>
- Maksimenko, V. A., Kurkin, S. A., Pitsik, E. N., Musatov, V. Y., Runnova, A. E., Efremova, T. Y., Hramov, A. E., & Pisarchik, A. N. (2018). Artificial Neural Network Classification of Motor-Related EEG: An Increase in Classification Accuracy by Reducing Signal Complexity. *Complexity*, 2018, 9385947. <https://doi.org/10.1155/2018/9385947>
- Naseem, S., Javed, K., Khan, M. J., Rubab, S., Khan, M. A., & Nam, Y. (2021). Integrated CWT-CNN for epilepsy detection using multiclass EEG dataset. *Computers, Materials and Continua*, 69(1), 471–486. <https://doi.org/10.32604/cmc.2021.018239>
- Pilato, M. S., Urban, A., Alkawadri, R., Barot, N. V., Castellano, J. F., Rajasekaran, V., Bagić, A. I., & Fong-Isariyawongse, J. S. (2020). EEG Findings in Coronavirus Disease. *Journal of Clinical Neurophysiology: Official Publication of the American Electroencephalographic Society*. <https://doi.org/10.1097/wnp.0000000000000752>
- Popov, E., & Fomenkov, S. (2016). Classification of hand motions in EEG signals using recurrent neural networks. *2016 2nd International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*, 1–4. <https://doi.org/10.1109/ICIEAM.2016.7911620>
- Purnamasari, P. D., & Junika, T. W. (2019). Frequency-based EEG Human Concentration Detection System Methods with SVM Classification. *2019 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom)*, 29–34. <https://doi.org/10.1109/CYBERNETICSCOM.2019.8875677>
- Sabancı, K., & Köklü, M. (2015). The Classification of Eye State by Using kNN and MLP Classification Models According to the EEG Signals. *International Journal of Intelligent Systems and Applications in Engineering*, 3(4), 127. <https://doi.org/10.18201/ijisae.75836>
- Saddam, M., Tjandrasa, H., & Navastara, D. A. (2017). Classification of alcoholic EEG using wavelet packet decomposition, principal component analysis, and combination of genetic algorithm and neural network. *2017 11th International Conference on Information Communication Technology and System (ICTS)*, 19–24. <https://doi.org/10.1109/ICTS.2017.8265600>
- Thanaraj, K. P., Parvathavarthini, B., Tanik, U. J., Rajinikanth, V., Kadry, S., & Kamalanand, K. (2020). Implementation of Deep Neural Networks to Classify EEG Signals using Gramian Angular Summation Field for Epilepsy Diagnosis. *Computer Vision and Pattern Recognition*. <https://arxiv.org/abs/2003.04534v1>
- Vecchio, F., Miraglia, F., Alù, F., Menna, M., Judica, E., Cotelli, M., & Rossini, P. M. (2020). Classification of Alzheimer's Disease with Respect to Physiological Aging with Innovative EEG Biomarkers in a Machine Learning Implementation. *Journal of Alzheimer's Disease*, 75, 1253–1261. <https://doi.org/10.3233/JAD-200171>
- Wang, Z., Na, J., & Zheng, B. (2020). An Improved kNN Classifier for Epilepsy Diagnosis. *IEEE Access*, 8, 100022–100030. <https://doi.org/10.1109/ACCESS.2020.2996946>
- Yean, C. W., Khairunizam, W., Omar, M. I., Murugappan, M., Zheng, B. S., Bakar, S. A., Razlan, Z. M., & Ibrahim, Z. (2018). Analysis of The Distance Metrics of KNN Classifier for EEG Signal in Stroke Patients. *2018 International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*, 1–4. <https://doi.org/10.1109/ICASSDA.2018.8477601>
- Zeng, H.; Wu, Z.; Zhang, J.; Yang, C.; Zhang, H.; Dai, G.; Kong, W. (2019). EG Emotion Classification Using an Improved SincNet-Based Deep Learning Model. *Brain Sci*, 9, 326.
- Zhang, X., Yao, L., Sheng, Q. Z., Kanhere, S. S., Gu, T., & Zhang, D. (2018). Converting Your Thoughts to Texts: Enabling Brain Typing via Deep Feature Learning of EEG Signals. *2018 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, 1–10. <https://doi.org/10.1109/PERCOM.2018.8444575>