



Klasifikasi Data Penderita Skizofrenia Menggunakan CNN-LSTM dan CNN-GRU pada Data Sinyal EEG 2D

Firmansyah ^{1*}, Dian Palupi Rini ², Sukemi ³

^{1*,2,3} Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Srinjaya, Kota Palembang, Provinsi Sumatera Selatan, Indonesia.

article info

Article history:

Received 28 March 2023

Received in revised form

6 August 2023

Accepted 28 August 2023

Available online October 2023

DOI:

<https://doi.org/10.35870/jti.k.v7i4.1072>

Keywords:

Schizophrenia;
Elektroensefalografi; Deep
Learning; Convolutional
Neural Network; Gated
Recurrent Unit; Long Short-
Term Memory.

Kata Kunci:

Skizofrenia;
Elektroensefalografi; Deep
Learning; Convolutional
Neural Network; Gated
Recurrent Unit; Long Short-
Term Memory.

abstract

Schizophrenia (SZ) is a brain disease with a chronic condition that affects the ability to think. Common symptoms that are often seen in SZ patients are hallucinations, delusions, abnormal behavior, speech disorders, and mood disorders. SZ patients can be diagnosed using electroencephalographic (EEG) signals. This study conducted a comparative analysis of the best method in EEG classification using the Deep Learning (DL) method. The author uses the 2D Convolutional Neural Network (2D-CNN) method with different layers. The first 2D-CNN uses a layer of Long Short Term memory(LSTM) and Gate Recurrent Unit(GRU). The dataset used consists of two types of EEG signals obtained from 39 healthy individuals and 45 schizophrenic patients during a resting state. Test results for the accuracy of the F1-score from 5 times testing the CNN method using the LSTM layer has the best accuracy value of 94.12% and 5 times testing the CNN method using the GRU layer has the best accuracy value of 94.12%.

abstract

Skizofrenia (SZ) adalah penyakit otak dengan kondisi kronis yang memengaruhi kemampuan berpikir. Gejala umum yang sering terlihat pada pasien SZ adalah halusinasi, delusi, perilaku abnormal, gangguan bicara, dan gangguan mood. Pasien SZ dapat didiagnosis menggunakan sinyal elektroensefalografi (EEG). Penelitian ini melakukan Analisis perbandingan metode terbaik dalam klasifikasi EEG menggunakan metode Deep Learning (DL). Penulis menggunakan metode 2D Convolutional Neural Network(2D-CNN) dengan layer berbeda. 2D-CNN Pertama menggunakan layer Long Short Term memory(LSTM) dan Gate Recurrent Unit(GRU). Dataset yang digunakan terdiri dari dua jenis sinyal EEG yang diperoleh dari 39 individu sehat dan 45 pasien skizofrenia selama keadaan istirahat. Hasil Pengujian akurasi F1-score dari 5 kali pengujian metode CNN yang menggunakan layer LSTM memiliki nilai akurasi terbaik sebesar 94,12% dan 5 kali pengujian metode CNN yang menggunakan layer GRU memiliki nilai akurasi terbaik sebesar 94,12%.

Corresponding Author. Email: firman.251122@gmail.com ^{1}.

1. Latar Belakang

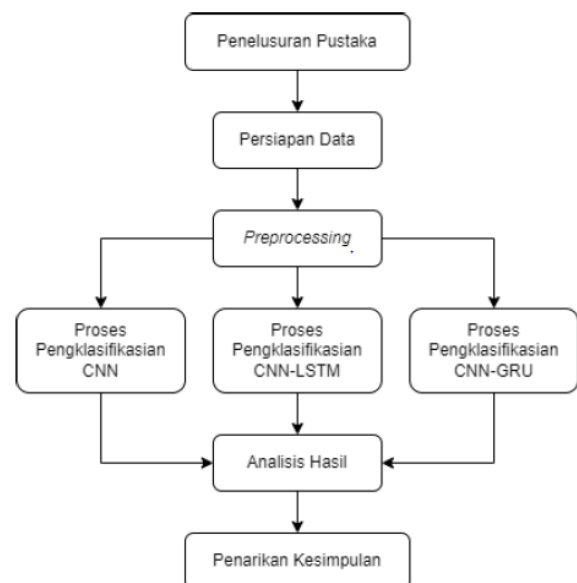
Skizofrenia (SZ) adalah penyakit otak dimana kondisi kronis yang mempengaruhi kemampuan berpikir. Gejala umum SZ yaitu halusinasi, delusi, perilaku abnormal, gangguan bicara, dan gangguan suasana hati [1]. Gangguan ini biasanya dimulai antara 18 dan 25 tahun pada pria dan antara 25 dan 35 tahun perempuan. Tanpa pengobatan, penderita skizofrenia dapat mengembangkan gangguan kesehatan mental lainnya dan signifikan masalah Kesehatan[2]. Pasien skizofrenia yang tidak mendapatkan pengobatan yang tepat lebih rentan mengalami stigmatisasi, diskriminasi, dan pelanggaran hak asasinya, harapan hidup penderita ini adalah antara 10 hingga 15 tahun dan risiko bunuh diri adalah 10% [2]. Untuk diagnosis gangguan mental seperti SZ, Elektroensefalografi (EEG) adalah alat yang ampuh karena dapat menginterpretasikan keadaan otak dengan baik dan banyak digunakan dalam aplikasi klinis [3]. EEG menjadi modalitas penting dalam mempelajari dan mendiagnosis berbagai gangguan otak [4]. Karena EEG bersifat non-invasif, aman, murah, dan menunjukkan konten temporal yang kaya [5]. Rekaman EEG berisi informasi yang diperoleh dari sinyal listrik yang dideteksi dengan menggunakan elektroda yang ditempatkan di berbagai area di kepala pasien. EEG dapat membantu para ahli mengevaluasi informasi yang sulit dianalisis di mana sinyal mentah tidak secara langsung menunjukkan anomali terkait penyakit [6].

Pada penelitian[2], menerapkan Koefisien Korelasi Pearson (PCC) untuk mendapatkan matriks korelasi sebagai masukan ke CNN mencapai hasil akurasi, spesifisitas, dan sensitivitas masing-masing 90%, 90%, 90%. Dalam penelitian Fadel *et al* (2020) menggunakan dataset sinyal EEG citra motor ditransformasikan menjadi gambar dua dimensi. Selanjutnya menggunakan Leave-One-Out-Cross-Validation (LOOCV) untuk mengevaluasi kinerja model [7]. Setelah itu, Klasifikasi CNN dan LSTM menghasilkan rata-rata akurasi pengujian 70,64% dan 68,13%. Penelitian Naira & Del Alamo (2019) menggunakan tiga dataset berbeda yaitu UCI-HAR, WISDM, dan PAMAP2 dengan pelatihan dataset UCI-HAR 21 peserta dengan 7352 sample dan pengujian 9 peserta, dataset WISDM diambil 29

peserta dataset pelatihan dan 7 peserta dataset pengujian, terakhir dataset PAMAP2 diambil dari 52 fitur. Hasil klasifikasi CNN dan GRU menghasilkan akurasi masing-masing 96,20%, 97,21%, dan 95,27% [8]. Penelitian sebelumnya telah membuktikan kemampuan untuk data eeg dengan berbagai model. tujuan penelitian ini adalah membandingkan CNN, LSTM, dan GRU untuk memudahkan para ahli dalam membedakan pasien SZ dan kontrol sehat serta gambar penyakit SZ ditafsirkan dengan jelas.

2. Metode Penelitian

Bahasan dari penelitian mengenai perbandingan metode CNN, LSTM dengan GRU dalam mendiagnosa penderita Skizofrenia. Adapun tahapan metodologi dalam penelitian kali ini terbagi menjadi tiga tahapan: 1) Melakukan preprocessing pada dataset, 2) Membandingkan metode CNN, LSTM dan GRU, dan 3) Menganalisis hasil yang sudah didapatkan dari ketiga metode tersebut. Dari ketiga tahapan tersebut maka akan didapatkan hasil berupa akurasi, recall, precision dan time, yang mana dari hasil perbandingan tersebut penulis akan mengetahui metode yang paling baik antara CNN, LSTM dan GRU untuk diagnosis pasien skizofrenia.



Gambar 1. Diagram Kerangka Penelitian


Penelusuran Pustaka

Pada tahapan ini dilakukan proses pembelajaran dari beberapa Pustaka dan literature yang relevan dengan

penelitian sebagai acuan, antara lain jurnal *Classification of People who Suffer Schizophrenia and Healthy People by EEG Signals using DeepLearning*, *Deep Convolutional Neural Network Model for Automated Diagnosis of Schizophrenia Using EEG Signals*, dan *Automatic Diagnosis of Schizophrenia in EEG Signals Using CNN-LSTM Models*.

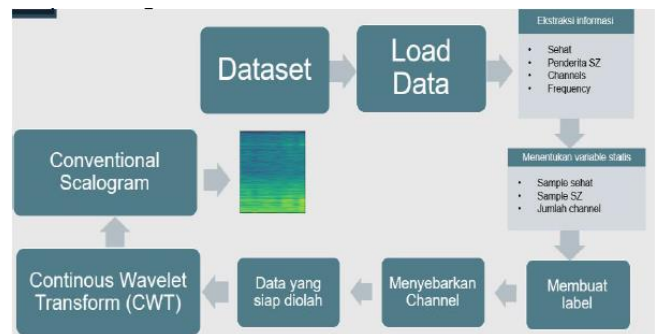
Persiapan Data

Dataset yang digunakan diperoleh dan disiapkan oleh Prof. N.N. Gorbachevskaya (Peneliti Terkemuka di Pusat Penelitian Kesehatan Mental) dan Dr. S.V. Borisov (Peneliti Senior Fakultas Biologi M.V. Lomonosov Moscow State University) di Laboratorium Neurofisiologi dan Antarmuka Komputer Neuro di M.V. Universitas Negeri Moskow Lomonosov tersedia akses terbuka[8]. Dataset terdiri dari dua jenis sinyal EEG yang diperoleh masing-masing dari 39 anak laki-laki sehat (11-13 tahun) dan 45 anak laki-laki (10-14 tahun) yang didiagnosis skizofrenia menggunakan wawancara klinis di Pusat Penelitian untuk gangguan Psikologis dari Akademi Ilmu Kedokteran Rusia. Selama perekaman, pasien dalam keadaan istirahat dengan mata tertutup selama 60 detik [9]. Setiap sinyal EEG dari dataset ini terdiri dari 16 saluran, yaitu, F7, F3, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 dan O2 yang dirujuk ke elektroda telinga berpasangan) direkam dengan pengambilan sampel frekuensi 128 Hz selama 1 menit. Semua pasien SZ (termasuk SZ masa kanak-kanak, gangguan skizotipikal dan skizoafektif) didiagnosis di Pusat Penelitian Kesehatan Mental (MHRC), menurut kriteria diagnostik SZ F20, F21, F25 dari ICD-10 Klasifikasi Gangguan Mental dan Perilaku, yang ditetapkan oleh International Statistical Classification of Diseases and Related Health Problems. Pasien tidak menjalani kemoterapi apapun selama pemeriksaan di MHRC [10].



Gambar 2. Sinyal EEG pasien SZ (kiri) dan sehat (kanan)

Preprocessing




Gambar 3. Preprocessing Data

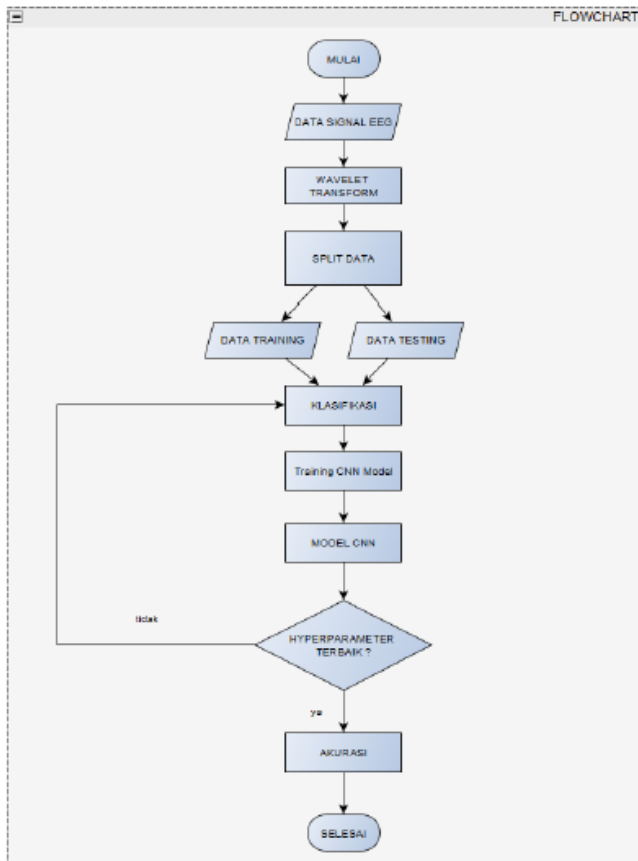
Pada tahapan ini, setiap sinyal EEG dataset dibagi menjadi 16 saluran F7, F3, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 dan O2. Sinyal EEG direkam dari kulit kepala peserta berdurasi 1 menit, masing-masing berisi voltase 7680 EEG dengan urutan mV, dan diambil frekuensi sampel pada 128Hz. Setiap saluran dibagi menjadi segmen-segmen dengan Panjang 5 detik, dengan menggabungkan segmen yang sesuai diperoleh vektor satu dimensi, masing-masing Panjangnya 10240. Selanjutnya panjang vektor dihitung sebagai (5s x 128 frekuensi sampel x 16 saluran). Vektor yang diperoleh ditransformasikan menjadi citra scalogram (224x224) menggunakan metode Continuous Wavelet Transform (CWT) dan morlet mavelet. Selanjutnya diperoleh gambar 1008 citra scalogram.

Convolutional Neural Network (CNN)

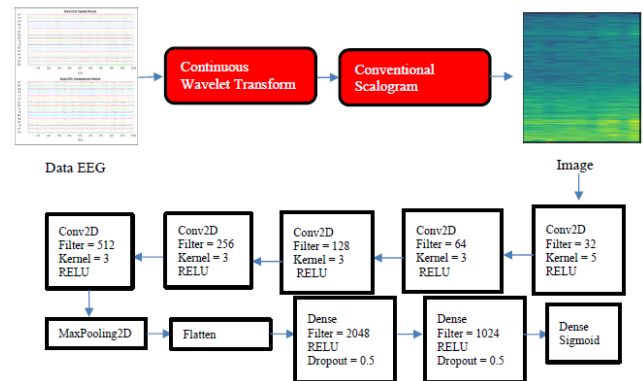
CNN adalah sejenis jaringan saraf umpan maju, yang sangat cocok untuk ekstraksi fitur dua dimensi dan dekat dengan jaringan saraf biologis nyata [11]. setiap lapisan model CNN terdiri dari lapisan konvolusi dengan filter dan kernel untuk membuat vektor fitur, lapisan penyatuan untuk mengurangi dimensi, dropout dan lapisan generalisasi untuk mengurangi over-fitting dan meningkatkan kinerja[12]. CNN dapat secara otomatis menemukan dan mengekstrak struktur internal deret waktu input untuk menghasilkan fitur mendalam untuk klasifikasi[13].



Gambar 4. Contoh pipeline pemrosesan EEG berbasis CNN satu dimensi



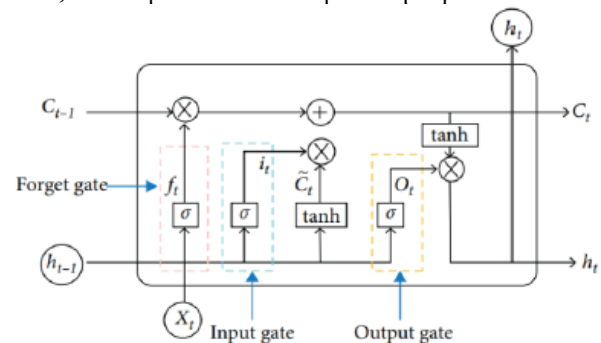
Gambar 5. Flowchart Model Arsitektur CNN yang diusulkan



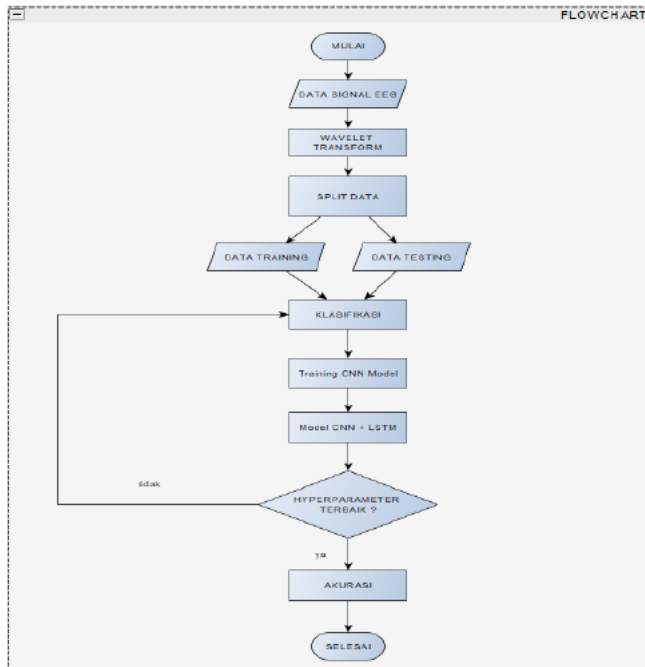
Gambar 6. Model Arsitektur 2D CNN yang diusulkan

Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM)

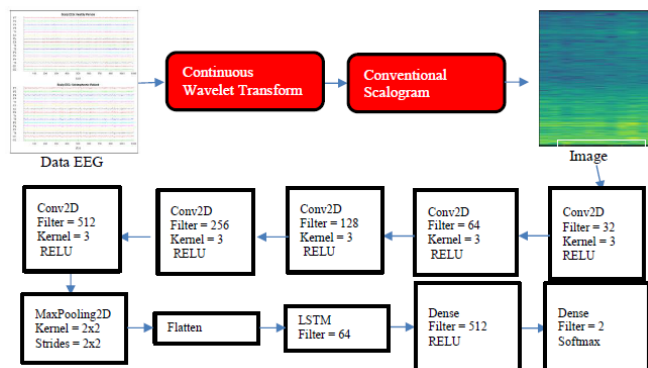
CNN-LSTM digunakan pada tugas-tugas varian seperti menemukan hubungan spatiotemporal dalam teks input untuk klasifikasi teks atau diagnosis gangguan depresi pada sinyal EEG. CNN-LSTM dihasilkan dari serangkaian lapisan konvolusional yang diikuti oleh beberapa lapisan LSTM. Pertama, ini mengekstrak fitur kaya menggunakan lapisan konvolusional dari data masukan. Kemudian berikan fitur ini ke lapisan LSTM yang bertanggung jawab untuk mengekstraksi informasi temporal. Terakhir, klasifikasi dilakukan dengan menerapkan lapisan yang terhubung penuh ke informasi temporal yang diperoleh lapisan LSTM[14]. CNN memiliki karakteristik memperhatikan fitur yang paling jelas di garis pandang, sehingga banyak digunakan dalam rekayasa fitur. LSTM memiliki sifat mengembangkan mengikuti urutan waktu, dan banyak digunakan dalam deret waktu. dan struktur utamanya adalah CNN dan LSTM, termasuk lapisan input, lapisan konvolusi satu dimensi, lapisan penyatuan, lapisan tersembunyi LSTM, dan lapisan koneksi penuh[15].



Gambar 7. Contoh diagram struktur CNN-LSTM [15]



Gambar 8. Flowchart Model CNN-LSTM




Gambar 9. Model Arsitektur 2D CNN-LSTM yang diusulkan

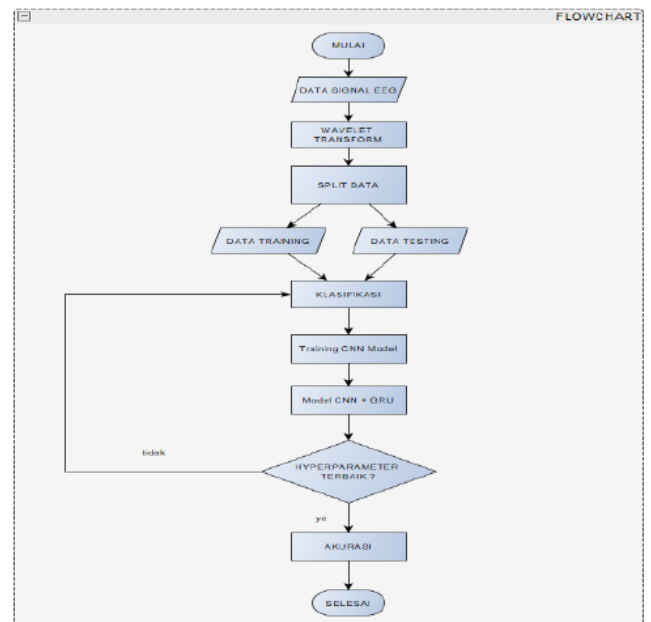
Convolutional Neural Network-Gate Recurrent Unit (CNN-GRU)

Karena di layer CNN yang terhubung penuh, unit saraf tidak terhubung satu sama lain. Jaringan GRU menggantikan lapisan CNN yang terhubung sepenuhnya untuk mengubah tugas klasifikasi menjadi tugas berurutan, di mana hasil klasifikasi dari setiap peta fitur ditambahkan ke perhitungan klasifikasi peta fitur berikutnya di lapisan tersembunyi yang sama untuk meningkatkan kinerja pengenalan CNN. Arsitektur CNN-GRU pada penelitian [16] ditunjukkan pada Gambar 10. Selanjutnya, metode dropout yang secara acak dapat menghapus beberapa unit neural pada lapisan tersembunyi digunakan untuk menghindari


kemungkinan masalah over-fitting pada model CNN-GRU.



Gambar 10. Contoh Struktur model hybrid CNN-GRU



Gambar 11. Flowchart CNN – GRU




Gambar 12. Model Arsitektur 2D CNN-GRU yang diusulkan.

3. Hasil dan Pembahasan


Pada pengujian terdapat parameter yang digunakan dalam menguji model CNN-LSTM dan CNN-GRU. Training data menggunakan ukuran batch berjumlah 8 dan setiap jaringan dilatih dengan 60 epoch, 100 epoch, 200 epoch, 500 epoch. Learning rate ditetapkan 10^{-4} . Sparse Categorical Crossentropy dipilih sebagai fungsi loss dan optimasi adam dipilih karena hasil yang baik dan waktu proses lebih pendek. Pelatihan dilakukan pada 80% data digunakan sebagai data pelatihan, sedangkan 20% data digunakan sebagai data testing.

Tabel 1. Hasil Pengujian Model CNN-LSTM dan CNN-GRU


Metode	Parameter		Classification Report			
	Epoch	Learning Rate	Akurasi	Pesisi	Recall	F1-Score
CNN	60	10^{-4}	0,97	-	-	-
CNN_LSTM	200	10^{-4}	0,94	0,95	0,94	0,94
CNN-GRU	100	10^{-5}	0,94	0,95	0,94	0,94




Gambar 13. Plot Akurasi CNN




Gambar 14. Plot Loss CNN




Gambar 15. Plot Akurasi CNN-LSTM




Gambar 16. Plot Loss CNN-LSTM




Gambar 17. Confusion Matrix CNN-LSTM



Gambar 18. Plot Akurasi CNN-GRU



Gambar 19. Plot Loss CNN-GRU



Gambar 20. Confusion Matrix CNN-GRU

Analisis Hasil Validasi CNN, CNN-LSTM, CNN-GRU

Validasi pengujian terhadap metode CNN-LSTM-GRU dilakukan pengujian sebanyak 5 kali. Hasil Rata-Rata Akurasi metode CNN mencapai hasil terbaik sebesar 97%. Sedangkan hasil rata-rata akurasi metode CNN-LSTM mencapai hasil terbaik sebesar 94,12%. Terakhir, hasil rata-rata akurasi metode CNN-GRU mencapai hasil terbaik sebesar 94,12%. Hasil dari metode CNN, LSTM, dan GRU menunjukkan bahwa metode CNN lebih baik dari metode CNN-LSTM dan CNN-GRU. Sedangkan metode CNN-LSTM menunjukkan hasil lebih baik dari metode CNN-GRU.

Hasil klasifikasi model CNN-LSTM dan CNN-GRU terdapat hasil yang overfitting seperti pada gambar 4.16 dan 4.19 bahwa grafik yang dihasilkan memiliki rentang yang jauh antara grafik training dan validasi. Kemudian terdapat hasil grafik yang tidak overfitting seperti pada gambar 4.1 dan 4.2 dengan menunjukkan grafik training dan validasi tidak memiliki rentang yang jauh atau sejajar. Pada penelitian ini setiap pengujian dilakukan dengan variasi yang berbeda yaitu dengan epoch atau learning rate yang berbeda, maka akan mempengaruhi hasil akurasi, presisi, recall, dan F1-score.

4. Kesimpulan

Pada penelitian ini, kesimpulan dari percobaan klasifikasi penderita Skizofrenia dengan menggunakan sinyal EEG subjek berbasis CNN dengan arsitektur CNN-LSTM dan CNN-GRU antara lain sebagai berikut:

- 1) Klasifikasi yang telah dilakukan dengan model CNN yang memiliki fitur spektral, segmen EEG temporal dan spektral dengan menggunakan model LSTM dan GRU sebagai inputnya dalam diagnosis pasien skizofrenia.
- 2) Model klasifikasi dengan menggunakan model CNN dengan arsitektur CNN dari semua uji coba model memiliki tingkat akurasi yang lebih tinggi dibandingkan dengan model CNN-LSTM dan CNN-GRU karena parameter tuning dapat mempengaruhi dan meningkatkan akurasi dari algoritma.

Berdasarkan kesimpulan penelitian, beberapa saran dapat dilakukan pada penelitian selanjutnya, yaitu:

- 1) Model CNN dengan fitur spektral, segmen EEG temporal dan spektral dapat dijadikan alternatif untuk diagnosis penderita skizofrenia dengan sinyal subjek EEG.
- 2) Model CNN dengan arsitektur CNN memiliki tingkat akurasi yang lebih tinggi dibandingkan dengan model CNN-LSTM dan CNN-GRU, oleh karena itu disarankan untuk menggunakan model CNN dengan arsitektur CNN pada penelitian selanjutnya.
- 3) Dapat dilakukan penambahan fitur atau parameter tuning pada model CNN untuk meningkatkan akurasi klasifikasi.
- 4) Dapat dilakukan penelitian lebih lanjut dengan jumlah subjek yang lebih banyak dan variasi data yang lebih luas untuk meningkatkan validitas dari hasil penelitian.

5. Daftar Pustaka

- [1] Baygin, M., 2021. An accurate automated schizophrenia detection using TQWT and statistical moment based feature extraction. *Biomedical Signal Processing and Control*, 68, p.102777. DOI: <https://doi.org/10.1016/j.bspc.2021.102777>.
- [2] Aydemir, E., Dogan, S., Baygin, M., Ooi, C.P., Barua, P.D., Tuncer, T. and Acharya, U.R., 2022, March. CGP17Pat: automated schizophrenia detection based on a cyclic group of prime order patterns using EEG signals. In *Healthcare* (Vol. 10, No. 4, p. 643). MDPI. DOI: <https://doi.org/10.3390/healthcare10040643>.
- [3] Shalbaf, A., Bagherzadeh, S. and Maghsoudi, A., 2020. Transfer learning with deep convolutional neural network for automated detection of schizophrenia from EEG signals. *Physical and Engineering Sciences in Medicine*, 43, pp.1229-1239. DOI: <https://doi.org/10.1007/s13246-020-00925-9>.
- [4] Afrooz, E. and Taghavi, M., 2022. Information-Theoretic Analysis of EEG Signals to Differentiate Schizophrenic Patients with Positive and Negative Symptoms and Control Group. *Iranian Journal of Psychiatry and Behavioral Sciences*, 16(3). DOI: <https://doi.org/10.5812/ijpbs-118000>.
- [5] Calhas, D., Romero, E. and Henriques, R., 2020. On the use of pairwise distance learning for brain signal classification with limited observations. *Artificial intelligence in medicine*, 105, p.101852. DOI: <https://doi.org/10.1016/j.artmed.2020.101852>.
- [6] Aslan, Z. and Akin, M., 2020. Automatic Detection of Schizophrenia by Applying Deep Learning over Spectrogram Images of EEG Signals. *Traitement du Signal*, 37(2). DOI: <https://doi.org/10.18280/ts.370209>.
- [7] Fadel, W., Kollod, C., Wahdow, M., Ibrahim, Y. and Ulbert, I., 2020, February. Multi-class classification of motor imagery EEG signals using image-based deep recurrent convolutional neural network. In *2020 8th International Winter Conference on Brain-Computer Interface (BCI)* (pp. 1-4). IEEE. DOI: <https://doi.org/10.1109/BCI48061.2020.9061622>.

- [8] Singh, K., Singh, S. and Malhotra, J., 2021. Spectral features based convolutional neural network for accurate and prompt identification of schizophrenic patients. *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, 235(2), pp.167-184. DOI: <https://doi.org/10.1177/0954411920966937>.
- [9] Torres Naira, C.A., 2020. Classification of people who suffer schizophrenia and healthy people by EEG signals using Deep Learning. *Int. J. Adv. Comput. Sci. Appl.*, vol. 10, no. 10, pp. 511–516, 2019, DOI: <https://doi.org/10.14569/ijacsa.2019.0101067>.
- [10] Phang, C.R., Ting, C.M., Noman, F. and Ombao, H., 2019. Classification of EEG-based brain connectivity networks in schizophrenia using a multi-domain connectome convolutional neural network. *arXiv preprint arXiv:1903.08858*. DOI: <https://doi.org/10.1109/JBHI.2019.2941222>.
- [11] Rong, Y., Wu, X. and Zhang, Y., 2020. Classification of motor imagery electroencephalography signals using continuous small convolutional neural network. *International Journal of Imaging Systems and Technology*, 30(3), pp.653-659. DOI: <https://doi.org/10.1002/ima.22405>.
- [12] Balam, V.P., Sameer, V.U. and Chinara, S., 2021. Automated classification system for drowsiness detection using convolutional neural network and electroencephalogram. *IET Intelligent Transport Systems*, 15(4), pp.514-524. DOI: <https://doi.org/10.1049/itr2.12041>.
- [13] Zhao, B., Lu, H., Chen, S., Liu, J. and Wu, D., 2017. Convolutional neural networks for time series classification. *Journal of Systems Engineering and Electronics*, 28(1), pp.162-169. DOI: <https://doi.org/10.21629/JSEE.2017.01.18>.
- [14] Saeedi, M., Saeedi, A. and Mohammadi, P., 2022. Schizophrenia Diagnosis via FFT and Wavelet Convolutional Neural Networks utilizing EEG signals. DOI: <https://doi.org/10.21203/rs.3.rs-1497490/v1>.
- [15] Lu, W., Li, J., Li, Y., Sun, A. and Wang, J., 2020. A CNN-LSTM-based model to forecast stock prices. *Complexity*, 2020, pp.1-10. DOI: <https://doi.org/10.1155/2020/6622927>.
- [16] Nguyen, V., Cai, J. and Chu, J., 2019, August. Hybrid CNN-GRU model for high efficient handwritten digit recognition. In *Proceedings of the 2nd international conference on artificial intelligence and pattern recognition* (pp. 66-71). DOI: <https://doi.org/10.1145/3357254.3357276>.