

PENINGKATAN AKURASI PREDIKSI CNN-LSTM DAN CNN-GRU UNTUK MENDIAGNOSA SKIZOFRENIA MELALUI SINYAL EEG

Gabriel Ekoputra Hartono Cahyadi¹, Sukemi², Dian Palupi Rini³

^{1,3} Jurusan Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

² Jurusan Sistem Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya

e-mail: ekoputra2695@gmail.com

Abstrak

Skizofrenia adalah gangguan jiwa yang umumnya muncul dalam bentuk halusinasi pendengaran, paranoia, atau cara berbicara dan berpikir yang kacau. Diagnosa penderita Skizofrenia dapat dilakukan dengan menggunakan pemeriksaan sinyal EEG. Penelitian ini melakukan analisa perbandingan metode yang terbaik untuk melakukan klasifikasi EEG menggunakan metode Deep Learning (DL). Penulis menggunakan metode 1D Convolutional Neural Network (1D CNN) yang menggunakan layer berbeda. 1D-CNN pertama menggunakan layer Long short-term memory (LSTM) dan 1D-CNN kedua menggunakan layer Gated Recurrent Unit (GRU). Dataset yang digunakan adalah 28 jenis sinyal EEG yang terdiri dari 14 penderita Skizofrenia dan 14 subjek normal. Hasil pengujian akurasi F1 Score dari CNN yang menggunakan layer LSTM memiliki nilai sebesar 95% dan CNN yang menggunakan layer GRU memiliki nilai 96%. Pengujian kedua metode tersebut menunjukkan bahwa nilai dari CNN-GRU lebih besar dari CNN-LSTM.

Kata kunci: skizofrenia, elektroensefalografi, deep learning, convolutional neural network, gated recurrent unit, long short-term memory

Abstract

Schizophrenia is a mental disorder that generally appears in the form of auditory hallucinations, paranoia, or disorganized speech and thinking. Schizophrenia can be diagnosed using an EEG signal examination. This study conducted a comparative analysis of the best method for classifying EEG using the Deep Learning (DL) method. The author uses the 1D Convolutional Neural Network (1D CNN) method which uses different layers. The first 1D-CNN uses the Long short-term memory (LSTM) layer and the second 1D-CNN uses the Gated Recurrent Unit (GRU) layer. The dataset used is 28 types of EEG signals consisting of 14 Schizophrenia sufferers and 14 normal subjects. The results of testing the accuracy of the F1 Score from CNN using the LSTM layer have a value of 95% and CNN using the GRU layer has a value of 96%. The test of both methods shows that the value of CNN-GRU is greater than that of CNN-LSTM.

Keywords: schizophrenia, electroencephalography, deep learning, convolutional neural network, gated recurrent unit, long short-term memory

1. PENDAHULUAN

Lebih dari 50% individu yang menerima diagnosis Skizofrenia memiliki masalah kejiwaan intermiten tetapi jangka panjang, dan sekitar 20% memiliki gejala kronis dan kecacatan [1]. Studi terbaru telah menunjukkan potensi penggunaan *Machine Learning* (ML) untuk mendiagnosis dan mengobati gangguan kesehatan mental terutama SZ [2]. Perkembangan terbaru dalam desain dan pelatihan arsitektur *neural network* telah memungkinkan penelitian untuk menyelesaikan tugas-tugas pembelajaran dengan metode *Deep Learning* (DL) terutama *Convolutional Neural Network* (CNN) dalam aplikasi medis dan juga untuk memproses sinyal EEG dengan sangat sukses [3].

Pada penelitian [4], model jaringan saraf konvolusi satu dimensi (1D CNN) baru diusulkan untuk pengenalan otomatis sinyal EEG normal dan abnormal dengan keakuratan 97%. Penelitian [5] merekam sinyal EEG dari 14 subjek dengan stimulasi

musik untuk prosesnya. Hasil simulasi dari algoritma yang diusulkan untuk klasifikasi dua tahap (negatif dan positif) dan klasifikasi tiga tahap (negatif, netral dan positif) emosi untuk 12 saluran aktif menunjukkan akurasi 97,42% dan 96,78% dan koefisien Kappa masing-masing 0,94 dan 0,93. Penelitian [6] melakukan analisa *deep learning* untuk klasifikasi sinyal EEG. LSTM dan NN yang ditingkatkan diusulkan untuk kinerja yang lebih baik masing-masing dengan akurasi 71,3% dan 78,9% dalam klasifikasi EEG. dengan eksperimen komparatif, menggunakan OpenBCI untuk mengumpulkan ide aksi EEG selama aksi statis dan aksi dinamis dan masing-masing menggunakan model pengenalan EEG Conv1D-GRU untuk melatih dan mengenali aksi.-Hasil eksperimen menunjukkan bahwa ide aksi gelombang otak lebih mudah untuk mengenali dalam keadaan statis.-akurasi pengenalan ide aksi gelombang otak dalam keadaan dinamis hanya 72,27%, dan akurasi pengenalan ide aksi gelombang otak dalam keadaan statis adalah 99,98%. Model CNN sebelas lapis diusulkan untuk mendeteksi SZ menggunakan sinyal EEG. Akurasi klasifikasi tinggi masing-masing 98,07% dan 81,26% diperoleh untuk pengujian berbasis non-subjek dan pengujian berbasis subjek, meskipun kumpulan datanya kecil [7]. Melalui penelitian ini, penulis menggunakan CNN, CNN-LSTM, dan CNN-GRU dan akan dilakukan perbandingan akurasi dari tiga model tersebut.

2. METODE PENELITIAN

Bahasan dari penelitian kali ini mengenai perbandingan metode CNN-LSTM dengan CNN-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 CNN-GRU.
3. Menganalisa hasil yang sudah didapatkan dari kedua 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 manakah metode yang sesuai untuk klasifikasi teks antara CNN-LSTM dan CNN-GRU.

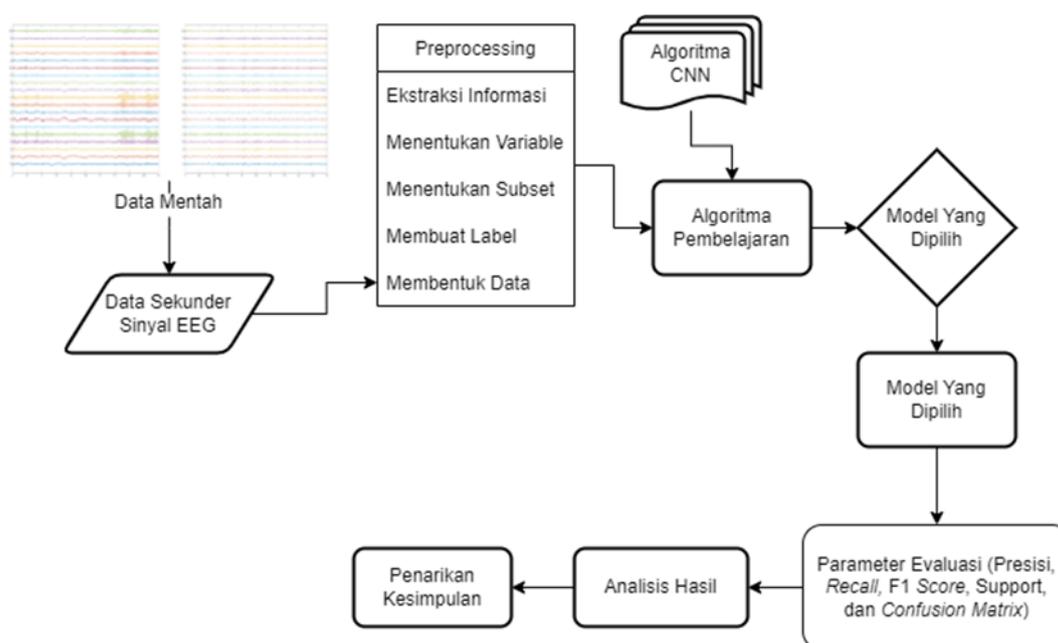
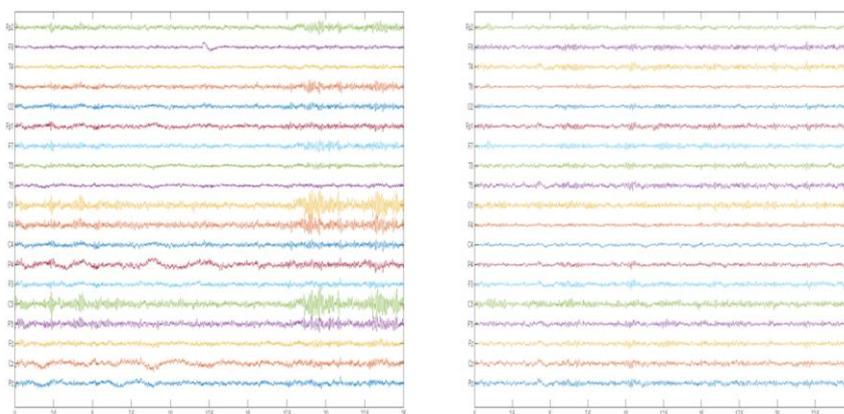


Diagram 1. Kerangka Penelitian

2.1 Persiapan Dataset

Dalam penelitian ini, penulis menggunakan dataset yang sudah disediakan oleh [8] pada tahun 2017 yang tersedia untuk umum. Rekaman sinyal EEG mencakup 14 pasien skizofrenia paranoid (7 perempuan) dengan usia mulai dari 27 hingga 32 dan 14 subjek normal (7 perempuan) dengan usia mulai dari 26 hingga 32 tahun. Data EEG direkam dengan mata tertutup selama lima belas menit. Rekaman diperoleh dari 19 elektroda yang ditempatkan di kulit kepala sesuai dengan sistem klasifikasi posisi elektroda standar internasional 10-20. Frekuensi sampling adalah 250Hz. Elektroda yang digunakan adalah Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1, O2. Sinyal yang diperoleh kemudian dibagi menjadi beberapa segmen, di mana sinyal dapat dianggap stasioner.



Gambar 1. Sinyal EEG normal (kiri) dan penderita Skizofrenia (kanan) [7]

2.2 Preprocessing

Tahapan pertama adalah menyiapkan dataset yang akan digunakan. Data yang digunakan merupakan data sekunder yang sudah dirancang ke dalam bentuk dokumen *Matlab* oleh [9] dan merupakan dataset yang dapat diperoleh secara umum. Dataset yang sudah disiapkan akan dikeluarkan menggunakan *Scipy*. *Scipy* adalah pustaka python yang sangat dapat digunakan untuk komputasi ilmiah dan memiliki metode yang memungkinkan untuk membaca dalam file *.mat*. Selanjutnya akan dilakukan ekstraksi informasi untuk membaca *data shape* untuk mengetahui data sinyal EEG yang sehat dan yang sakit serta untuk melihat *channels* dan frekuensi data sinyal. Dataset yang digunakan memiliki 19 channels dan frekuensi sepanjang 180000. Kemudian akan ditentukan variable statis dari jumlah *channels* dan frekuensi yang telah diketahui. Pada penelitian ini akan menggunakan jumlah subset sebanyak 15000.

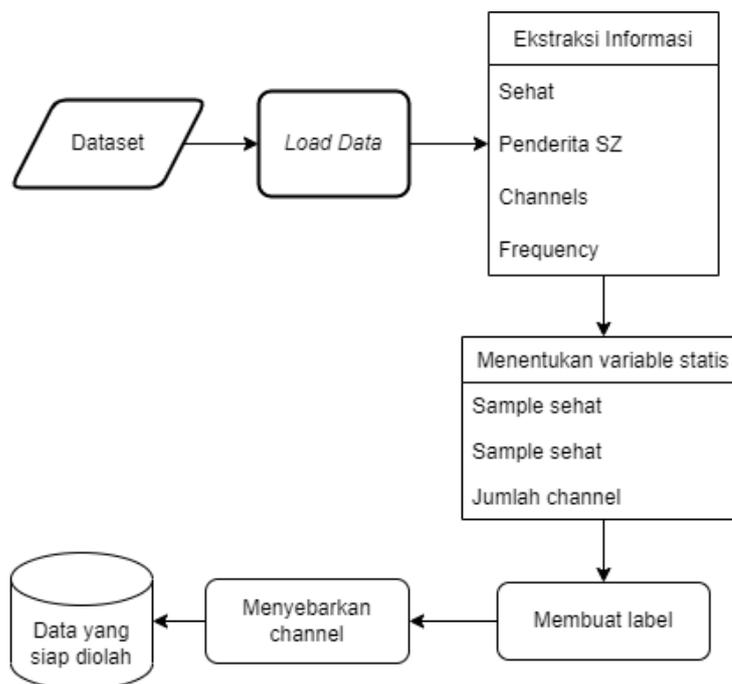
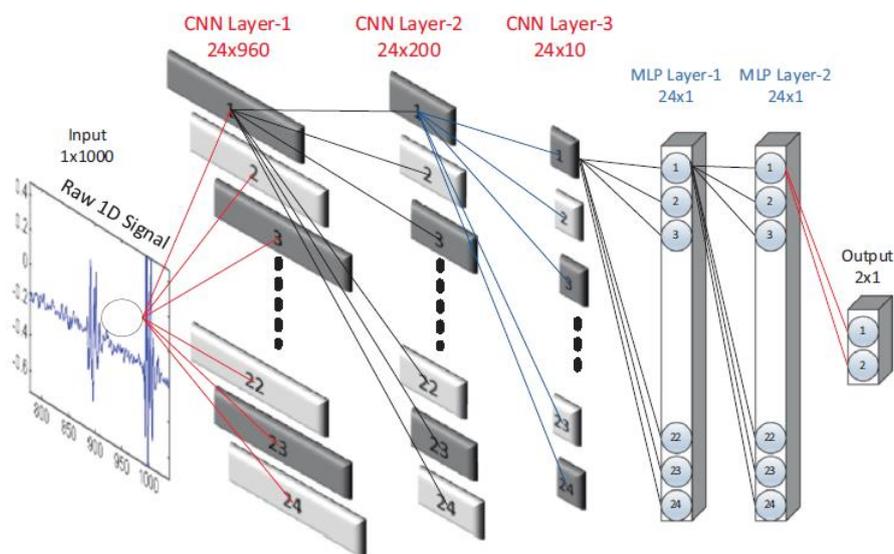


Diagram 2. Diagram tahapan *preprocessing* data.

2.3 Convolutional Neural Network (CNN)

Istilah Deep Learning atau Deep Neural Network mengacu pada Artificial Neural Network (ANN) dengan multi layer [10]. Salah satu deep neural network yang paling populer adalah Convolutional Neural Network (CNN). Aspek yang paling menguntungkan dari CNN adalah mengurangi jumlah parameter dalam ANN [11]. CNN merupakan salah satu jenis feedforward neural network yang mampu mengekstrak fitur dari data dengan struktur konvolusi. Berbeda dengan metode ekstraksi fitur tradisional, CNN tidak perlu mengekstrak fitur secara manual [12]. Salah satu perbedaan utama adalah bahwa neuron yang lapisan dalam CNN terdiri dari neuron yang diatur ke dalam tiga dimensi, dimensi spasial input (tinggi dan lebar) dan kedalaman. Kedalaman tidak mengacu pada jumlah total lapisan dalam ANN, tetapi dimensi ketiga dari volume aktivasi. [13].

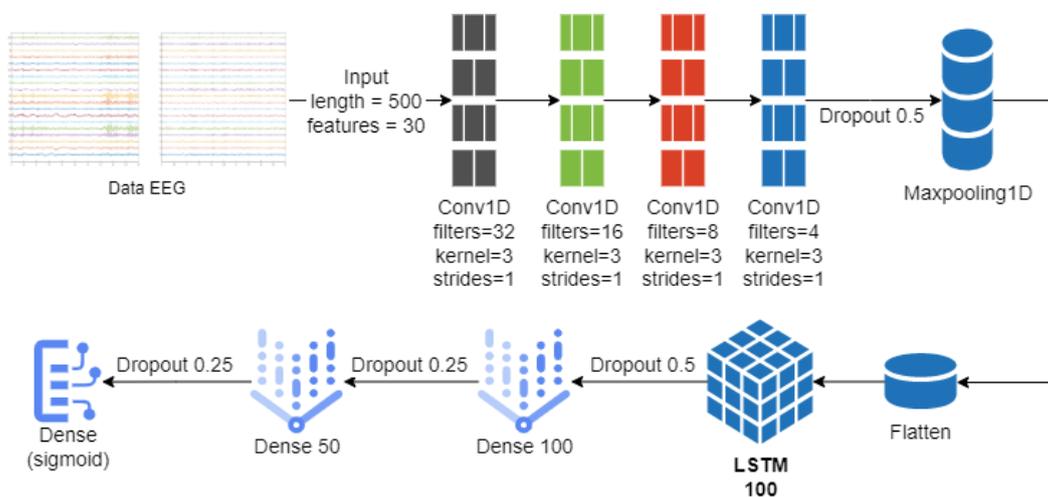
CNN dalam konvensional yang disajikan di bagian sebelumnya dirancang untuk beroperasi secara eksklusif pada data 2D seperti gambar dan video. Inilah sebabnya mengapa sering disebut sebagai "2D CNN". Sebagai alternatif, versi modifikasi dari CNN 2D disebut 1D CNN. Dalam studi terbaru yang disebutkan di atas, CNN 1D telah menunjukkan kinerja yang unggul pada aplikasi yang memiliki data berlabel terbatas dan variasi sinyal tinggi yang diperoleh dari sumber yang berbeda salah satunya adalah sinyal EEG [14].



Gambar 2. Contoh arsitektur 1D CNN [14].

2.3 Klasifikasi Menggunakan CNN-LSTM

Dalam model CNN-LSTM, lapisan konvolusi digunakan pada lapisan pertama model untuk mengekstrak fitur dan menemukan pola lokal. Kemudian, outputnya diterapkan ke lapisan RNN. Secara eksperimental, lapisan konvolusi mengekstraksi pola lokal dan spasial dari sinyal EEG lebih baik dibandingkan dengan RNN. Selain itu, menambahkan lapisan konvolusi ke RNN memungkinkan pemeriksaan data yang lebih akurat. Pada bagian ini, berbagai model CNN-LSTM untuk diagnosis SZ akan diusulkan.



Gambar 1. Model arsitektur CNN-LSTM yang diusulkan.

Model CNN-LSTM yang diusulkan pertama terdiri dari 13 max, dropout, CNN, LSTM, flatten, pooling, dan density layer. Rincian model yang diusulkan disajikan pada Tabel 1. Arsitektur ini mencakup tiga lapisan konvolusi; tiga layer dropout dengan rate yang berbeda, satu layer Max-Pooling, dan satu layer GlobalAveragePooling1D, satu layer LSTM, dan terakhir, dua layer padat dengan fungsi aktivasi ReLU dan sigmoid.

Pada model CNN-LSTM kedua, jaringan ini mencakup 13 lapisan, dan mirip dengan model sebelumnya, terdiri dari lapisan CNN dan LSTM. Seperti dapat dilihat pada Tabel 2 lapisan pertama dari model yang diusulkan ini identik dengan model CNN-LSTM sebelumnya. Lapisan padat dengan 50 neuron dan fungsi aktivasi ReLU digunakan pada lapisan ke-11 arsitektur ini. Lapisan ke-12 terdiri dari dropout dengan rate = 0,25. Pada akhirnya, pada lapisan ke-13, lapisan padat dengan fungsi aktivasi sigmoid untuk klasifikasi digunakan. Yang berbeda pada model kedua adalah lapisan keenam diganti dengan Flatten.

Table 1. 1st CNN-LSTM model

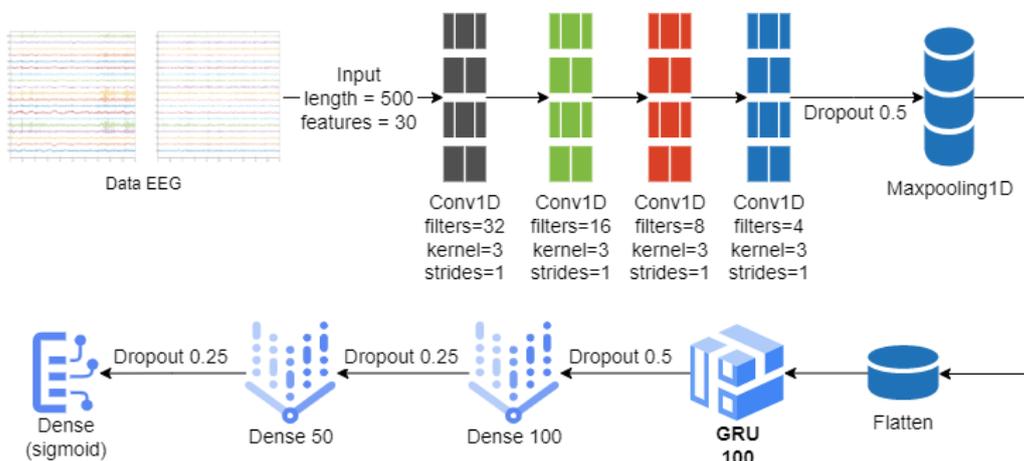
<i>Layer</i>	<i>Filters</i>	<i>Kernels</i>	<i>Stride</i>	<i>Rate</i>	<i>Activation</i>
Conv1d	32	3	1	-	ReLU
Conv1d	16	3	1	-	ReLU
Conv1d	8	3	1	-	ReLU
Conv1d	4	3	1	-	ReLU
MaxPooling1D	-	2	1	-	-
GlobalAveragePooling1D	-	-	-	-	-
LSTM	100	-	-	-	-
Dropout	-	-	-	0.5	-
Dense	100	-	-	-	ReLU
Dropout	-	-	-	0.5	-
Dense	50	-	-	-	ReLU
Dropout	-	-	-	0.5	-
Dense	1	-	-	-	Sigmoid

Table 2. 2nd CNN-LSTM model

<i>Layer</i>	<i>Filters</i>	<i>Kernels</i>	<i>Stride</i>	<i>Rate</i>	<i>Activation</i>
Conv1d	32	3	1	-	ReLU
Conv1d	16	3	1	-	ReLU
Conv1d	8	3	1	-	ReLU
Conv1d	4	3	1	-	ReLU
MaxPooling1D	-	2	1	-	-
Flatten	-	-	-	-	-
LSTM	100	-	-	-	-
Dropout	-	-	-	0.5	-
Dense	100	-	-	-	ReLU
Dropout	-	-	-	0.5	-
Dense	50	-	-	-	ReLU
Dropout	-	-	-	0.5	-
Dense	1	-	-	-	Sigmoid

2.4 Klasifikasi Menggunakan CNN-GRU

Pada model klasifikasi CNN-GRU tidak jauh berbeda dengan proses pengklasifikasian menggunakan CNN-LSTM. Berbeda dengan model sebelumnya, model selanjutnya menggunakan jumlah layer yang sama namun layer LSTM digantikan dengan GRU.



Gambar 2. Contoh Arsitektur CNN-GRU

Model CNN-GRU yang diusulkan pertama terdiri dari 13 max, dropout, CNN, GRU, globalaveragepooling1d, maxpooling, dan density layer. Rincian model yang diusulkan disajikan pada Tabel 3. Arsitektur ini mencakup empat lapisan konvolusi; tiga layer dropout dengan rate yang berbeda, satu layer Max-Pooling, dan satu layer GlobalAveragePooling1D, satu layer GRU, dan terakhir, dua layer padat dengan fungsi aktivasi ReLU dan sigmoid. Pada model yang kedua jumlah layer sama dengan jumlah layer yang terdapat pada model pertama namun pada layer GlobalAveragePooling1D diganti dengan Flatten dan ditampilkan pada Tabel 4.

Table 3. 1st CNN-GRU model

<i>Layer</i>	<i>Filters</i>	<i>Kernels</i>	<i>Stride</i>	<i>Rate</i>	<i>Activation</i>
Conv1d	32	3	1	-	ReLU
Conv1d	16	3	1	-	ReLU
Conv1d	8	3	1	-	ReLU
Conv1d	4	3	1	-	ReLU
MaxPooling1D	-	2	1	-	-
GlobalAveragePooling1D	-	-	-	-	-
GRU	100	-	-	-	-
Dropout	-	-	-	0.5	-
Dense	100	-	-	-	ReLU
Dropout	-	-	-	0.5	-
Dense	50	-	-	-	ReLU
Dropout	-	-	-	0.5	-

Dense	1	-	-	-	Sigmoid
-------	---	---	---	---	---------

Table 4. 2nd CNN-GRU model

<i>Layer</i>	<i>Filters</i>	<i>Kernels</i>	<i>Stride</i>	<i>Rate</i>	<i>Activation</i>
Conv1d	32	3	1	-	ReLU
Conv1d	16	3	1	-	ReLU
Conv1d	8	3	1	-	ReLU
Conv1d	4	3	1	-	ReLU
MaxPooling1D	-	2	1	-	-
Flatten	-	-	-	-	-
GRU	100	-	-	-	-
Dropout	-	-	-	0.5	-
Dense	100	-	-	-	ReLU
Dropout	-	-	-	0.5	-
Dense	50	-	-	-	ReLU
Dropout	-	-	-	0.5	-
Dense	1	-	-	-	Sigmoid

3. HASIL DAN ANALISIS

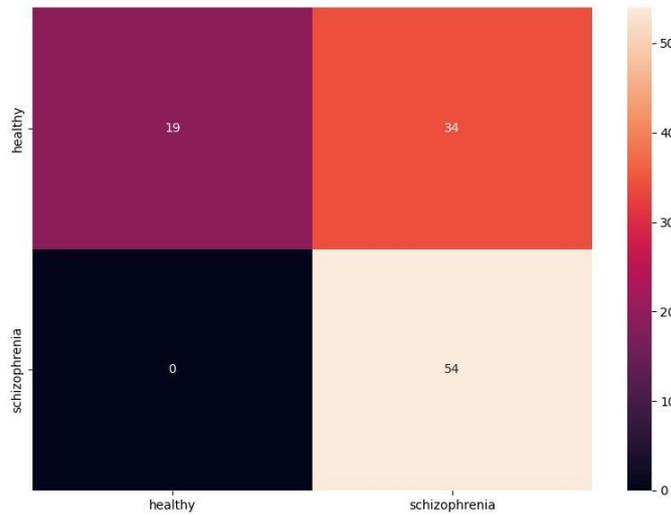
Pada pengujian pertama terdapat parameter yang digunakan dalam menguji model CNN-LSTM. Untuk bagian training model, ukuran batch berjumlah 128 dan setiap jaringan dilatih dengan 128 epoch. Selain itu, tingkat η -learning rate awal ditetapkan pada 0,001 dan jika tidak ada perbaikan setelah 50 epoch, learning rate diturunkan dengan faktor 0,1. Binary Cross Entropy dipilih sebagai fungsi loss dan pada fase optimasi, algoritma ADAM dipilih karena hasil yang superior dan run-time yang lebih pendek. Pelatihan dilakukan pada 80% data untuk klasifikasi pasien skizofrenia dan subjek sehat dan sisanya digunakan untuk mengevaluasi kinerja pengklasifikasi menggunakan berbagai metrik (akurasi, sensitivitas, dan spesifisitas).

3.1. Hasil Pengujian Model CNN-LSTM

Pada pengujian pertama ini terdapat hasil parameter yang berasal dari proses menjalankan jumlah layer yaitu total parameter yang berjumlah 59,373 dan Trainable Parameter yang berjumlah sama. Hasil yang kedua memiliki total parameter berjumlah 203,373 dan Trainable parameter yang sama. Hasil akhir dari model CNN-LSTM pertama ditunjukkan dalam Tabel 5 dan Tabel 6.

Tabel 5. Nilai Akurasi Model CNN-LSTM Pertama

	<i>Precision</i>	<i>Recall</i>	<i>F1 score</i>	<i>Support</i>
0.0	1.00	0.36	0.53	53
1.0	0.61	1.00	0.76	54
accuracy			0.68	107
macro avg	0.81	0.68	0.64	107
wighted avg	0.81	0.68	0.65	107



Gambar 3. Confusion Matrix Model CNN-LSTM Pertama

Tabel 6. Nilai Akurasi CNN-LSTM Kedua

	<i>Precision</i>	<i>Recall</i>	<i>F1 score</i>	<i>Support</i>
0.0	1.00	0.91	0.95	53
1.0	0.92	1.00	0.96	54
accuracy			0.95	107
macro avg	0.96	0.95	0.95	107
wighted avg	0.96	0.95	0.95	107



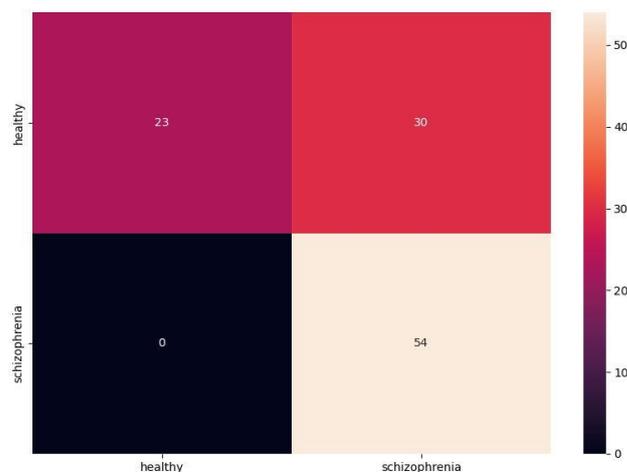
Gambar 4. Confusion Matrix Model CNN-LSTM Kedua

3.2. Hasil Pengujian Model CNN-GRU

Pada pengujian pertama ini terdapat hasil parameter yang berasal dari proses menjalankan jumlah layer yaitu total parameter yang berjumlah 49.173 dan Trainable Parameter yang berjumlah sama. Pada hasil pengujian kedua total parameter berjumlah 157.173 dan Trainable Parameter yang sama. Hasil akhir dari model CNN-LSTM pertama ditunjukkan dalam tabel 7 dan Tabel 8

Tabel 7. Nilai Akurasi Model CNN-GRU Pertama

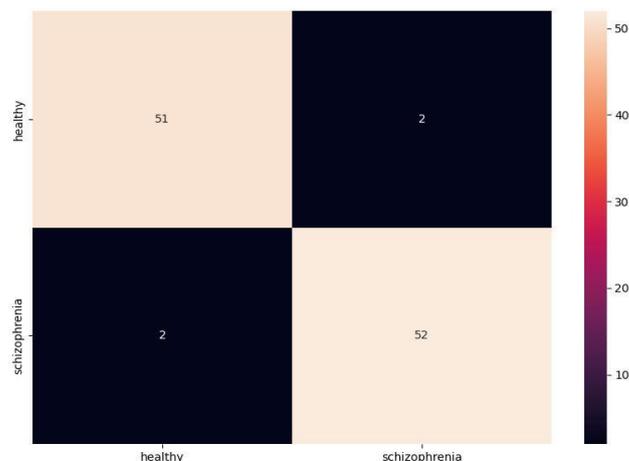
	<i>precision</i>	<i>recall</i>	<i>f1 score</i>	<i>support</i>
0.0	1.00	0.43	0.61	53
1.0	0.64	1.00	0.78	54
accuracy			0.72	107
macro avg	0.82	0.72	0.69	107
wighted avg	0.82	0.72	0.69	107



Gambar 5. Confusion Matrix Model CNN-GRU Pertama

Tabel 8. Nilai Akurasi Model CNN-GRU Kedua

	<i>precision</i>	<i>recall</i>	<i>f1 score</i>	<i>support</i>
0.0	0.96	0.96	0.96	53
1.0	0.96	0.96	0.96	54
accuracy			0.96	107
macro avg	0.96	0.96	0.96	107
wighted avg	0.96	0.96	0.96	107



Gambar 6. Confusion Matrix Model CNN-GRU Kedua

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. Model CNN-LSTM yang menggunakan layer Flatten memiliki tingkat akurasi yang lebih tinggi dari model CNN-LSTM yang menggunakan layer Global Average Pooling 1D.
2. Hasil dari perbandingan layer juga berpengaruh pada model CNN-GRU dimana tingkat akurasi menggunakan Flatten lebih tinggi dari tingkat akurasi menggunakan Average Global Pooling 1D.
3. Model klasifikasi dengan menggunakan model CNN dengan arsitektur CNN-GRU dari semua ujia coba model memiliki tingkat akurasi yang lebih tinggi dibandingkan dengan model CNN-LSTM.

4.1 Saran

Penelitian ini memiliki beberapa keterbatasan seperti proses preprocessing yang masih bersifat eksperimental. Selain itu juga belum adanya kurva untuk menampilkan nilai Training and Validation dari kedua model. Hal ini terjadi karena keterbatasan penulis dalam menguasai bahasa Phyton terutama dalam deep learning. Sehingga, diperlukan studi yang lebih luas lagi, misalnya dengan melakukan penambahan jumlah model dengan bentuk data shape yang berbeda, metode preprocessing yang berbeda, penambahan jumlah filter pada tiap layer Konvolusi, dan penambahan fitur testing model menggunakan dataset yang berbeda.

REFERENCES

- [1] M. J. Owen, A. Sawa, and P. B. Mortensen, "Schizophrenia," *Lancet*, vol. 388, no. 10039, pp. 86–97, 2016, doi: 10.1016/S0140-6736(15)01121-6.
- [2] L. Zhang, "EEG Signals Classification Using Machine Learning for the Identification and Diagnosis of Schizophrenia," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 4521–4524, 2019, doi: 10.1109/EMBC.2019.8857946.
- [3] A. Shalhaf, S. Bagherzadeh, and A. Maghsoudi, "Transfer learning with deep convolutional neural network for automated detection of schizophrenia from EEG signals," *Phys. Eng. Sci. Med.*, vol. 43, no. 4, pp. 1229–1239, 2020, doi: 10.1007/s13246-020-00925-9.
- [4] Ö. Yıldırım, U. B. Baloglu, and U. R. Acharya, "A deep convolutional neural network model for automated identification of abnormal EEG signals," *Neural Comput. Appl.*, vol. 32, no. 20, pp. 15857–15868, 2020, doi: 10.1007/s00521-018-3889-z.
- [5] S. Sheykhivand, Z. Mousavi, T. Y. Rezaii, and A. Farzamnia, "Recognizing Emotions Evoked by Music Using CNN-LSTM Networks on EEG Signals," *IEEE Access*, vol. 8, pp. 139332–139345, 2020, doi: 10.1109/ACCESS.2020.3011882.
- [6] P. Nagabushanam, S. Thomas George, and S. Radha, "EEG signal classification using LSTM and improved neural network algorithms," *Soft Comput.*, vol. 24, no. 13, pp. 9981–10003, 2020, doi: 10.1007/s00500-019-04515-0.
- [7] S. L. Oh, J. Vicnesh, E. J. Ciaccio, R. Yuvaraj, and U. R. Acharya, "Deep convolutional neural network model for automated diagnosis of Schizophrenia using EEG signals," *Appl. Sci.*, vol. 9, no. 14, 2019, doi: 10.3390/app9142870.
- [8] E. Olejarczyk and W. Jernajczyk, "Graph-based analysis of brain connectivity in schizophrenia," *PLoS One*, vol. 12, no. 11, pp. 1–28, 2017, doi: 10.1371/journal.pone.0188629.
- [9] M. Saeedi, A. Saeedi, and P. Mohammadi, "Schizophrenia Diagnosis via FFT and Wavelet Convolutional Neural Networks utilizing EEG signals," 2022.
- [10] A. K. Jain, J. Mao, and K. M. Mohiuddin, "Artificial neural networks: A tutorial," *Computer (Long. Beach. Calif.)*, vol. 29, no. 3, pp. 31–44, 1996, doi: 10.1109/2.485891.
- [11] S. Albawi, T. A. M. Mohammed, and S. Alzawi, "Understanding of a Convolutional Neural Network," *2017 Int. Conf. Eng. Technol.*, pp. 1–6, 2017, [Online]. Available: <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- [12] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE Trans. Neural Networks Learn. Syst.*, pp. 1–21, 2021, doi: 10.1109/tnnls.2021.3084827.
- [13] K. O'Shea and R. Nash, "An Introduction to Convolutional Neural Networks," *ArXiv e-prints*, pp. 1–11, 2015, [Online]. Available: <http://arxiv.org/abs/1511.08458>
- [14] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, and D. J. Inman, "1D convolutional neural networks and applications: A survey," *Mech. Syst. Signal Process.*, vol. 151, p. 107398, 2021, doi: 10.1016/j.ymsp.2020.107398.