



Pengembangan Model Klasifikasi Kejang Epilepsi *Multiclass* pada Sinyal EEG Menggunakan CNN+BI-LSTM

Bima Dinda Nurwibowo^{1*}, Ahmad Saikhu²

^{1,2} Departemen Teknik Informatika, Fakultas Teknologi Elektro dan Informatika Cerdas, Institut Teknologi Sepuluh Nopember, Indonesia

Jl. Teknik Kimia, Keputih, Kec. Sukolilo, Surabaya, Jawa Timur, Indonesia

E-mail*: bimanurwibawa@gmail.com

ABSTRACT

Epilepsy is a neurological disorder that requires accurate identification of seizure types for effective treatment. The classification of EEG signals during normal, interictal, and ictal periods is crucial in aiding the diagnosis of epilepsy. However, automatic EEG analysis is highly challenging due to the signal's complexity and intricate patterns that are often not visible to non-expert professionals. To address this challenge, this research develops a multiclass epilepsy seizure classification model using a deep learning approach based on Convolutional Neural Network (CNN) and Bidirectional Long Short-Term Memory (Bi-LSTM). CNN is responsible for automatically extracting features from shorter EEG segments, while Bi-LSTM aids in understanding complex temporal patterns. The preprocessing process involves signal segmentation, independent component separation and normalization, as well as data augmentation using Cubic Spline Interpolation (CSI). The CNN+Bi-LSTM model was tested in two classification scenarios: original data and augmented data, along with two subset combinations (A/D/E and B/D/E). Test results show that the model achieved a highest accuracy of 99.87% on augmented data, surpassing previous classification methods.

Keywords : *Classification, Convolutional Neural Network (CNN), Bidirectional Long Short-Term Memory (Bi-LSTM), Epileptic Seizure Detection, EEG Signal.*

ABSTRAK

Epilepsi merupakan gangguan neurologis yang membutuhkan identifikasi jenis kejang yang akurat untuk pengobatan yang efektif. Klasifikasi sinyal EEG pada periode normal, interiktal, dan iktal sangat penting dalam membantu diagnosis epilepsi. Namun, analisis EEG secara otomatis sangat menantang karena kompleksitas sinyal yang tinggi dan pola-pola kompleks yang sering kali tidak terlihat oleh profesional non-ahli. Untuk mengatasi kesulitan ini, penelitian ini mengembangkan model klasifikasi kejang epilepsi multiclass menggunakan pendekatan *deep learning* berbasis *Convolutional Neural Network* (CNN) dan *Bidirectional Long Short-Term Memory* (Bi-LSTM). CNN berperan dalam mengekstraksi fitur secara otomatis dari segmen EEG yang lebih pendek, sementara Bi-LSTM membantu dalam memahami pola temporal yang kompleks. Proses prapemrosesan melibatkan segmentasi sinyal, pemisahan komponen independen dan normalisasi, serta augmentasi data dengan *Cubic Spline Interpolation* (CSI). Model CNN+Bi-LSTM diuji pada dua skenario klasifikasi, yakni data asli dan data augmentasi, serta dua kombinasi subset (A/D/E dan B/D/E). Hasil pengujian menunjukkan model mencapai akurasi tertinggi sebesar 99.87% pada data augmentasi, yang melebihi metode klasifikasi sebelumnya.

Kata Kunci : *Klasifikasi, Convolutional Neural Network (CNN), Bidirectional Long Short-Term Memory (Bi-LSTM), Deteksi Kejang Epilepsi, Sinyal EEG.*

Naskah diterima 11 November 2024; Revisi 25 November 2024; Diterima 10 Februari 2025. Tanggal Publikasi 01 Maret 2025
Jurnal teknika berada pada lisensi *Creative Commons Attribution-ShareAlike 4.0 International License*
DOI: [10.30736/jt.v17i1.1354](https://doi.org/10.30736/jt.v17i1.1354), Hal 21 -28



1. PENDAHULUAN

Epilepsi adalah gangguan otak yang ditandai dengan gangguan fungsi otak normal yang berulang dan tidak dapat diprediksi, yang disebut serangan epilepsi (Fisher dkk., 2005). Menurut WHO, epilepsi mempengaruhi sekitar 50 juta orang global, dengan insiden lebih tinggi di negara berpenghasilan rendah dan menengah. Epilepsi berdampak signifikan pada ekonomi melalui biaya perawatan, kematian dini, dan kehilangan produktivitas, serta menghadapi stigma dan diskriminasi di seluruh dunia. Perawatan dengan pemberian obat berdosisi tinggi memberikan efek samping bagi penderita. Selain itu pengobatan juga dinilai kurang efektif bagi 20 hingga 40% pasien penderita epilepsi. Dari kasus epilepsi yang terjadi, 30% tidak dapat dikontrol dengan obat atau pembedahan (Manasvi Bhat dkk., 2019).

Elektroensefalogram (EEG) merupakan satu metode yang paling umum digunakan oleh untuk mengidentifikasi epilepsi dengan memantau aktivitas pada otak (Eviyanti et al., 2022). Selama prosedur tes EEG, ahli kesehatan menilai sekitar 100 halaman aktivitas, memeriksa bentuk gelombang dasar serta respons terhadap rangsangan, yang memakan banyak waktu dan tenaga (Nanthini dkk., 2022). Tidaklah sederhana dan masih menjadi tantangan dalam melakukan klasifikasi kejang epilepsi menggunakan data EEG (Rohan dkk., 2020). Banyak ilmuwan mempublikasikan karya mereka tentang kejang epilepsi otomatis, tetapi sebagian besar hanya menggunakan dua kategori, sinyal kejang EEG epilepsi dan sinyal kejang EEG non-epilepsi.

Identifikasi jenis kejang berperan dalam membantu ahli saraf mendiagnosis dan manajemen gangguan kejang epilepsi untuk menentukan obat yang tepat dan dosisnya, sehingga serangan kejang epilepsi dapat dicegah dan mengurangi tingkat keparahan pasien (Shakeel dkk., 2021). Sangat penting untuk membedakan periode EEG normal, periode EEG interictal dan sinyal periode EEG ictal untuk mengklasifikasikan jenis kejang epilepsi (Mamun Or Rashid & Ahmad, 2017).

Analisis EEG secara otomatis dianggap sulit karena kompleksitas sinyal yang tinggi. EEG dapat mengandung pola yang sulit untuk diamati oleh para profesional yang tidak terlatih. Karena kesulitan ini, metode komputasi tidak diterapkan pada seluruh


EEG, tetapi pada segmen dengan durasi waktu yang lebih pendek. Setiap segmen EEG yang dipilih diasumsikan stasioner (Tales Oliva dkk., 2019) (Oliva & Rosa, 2021). Masih rumit dan membutuhkan banyak penguasaan saat melakukan prapemrosesan dan mencoba mengekstrak fitur representatif terbaik dari sinyal mentah (Ahmed M. dkk., 2023).

Dalam penelitian ini mengusulkan model klasifikasi menggunakan *deep learning* untuk deteksi kejang epilepsi pada data EEG untuk kelas normal, interictal dan ictal. CNN digunakan untuk mengekstraksi fitur secara otomatis dari data EEG sedangkan Bi-LSTM digunakan untuk memahami

hubungan temporal atau pola jangka panjang dari data tersebut.

2. METODE

Diagram blok keseluruhan dari metode yang diusulkan diilustrasikan pada Gambar 1.




Gambar 1. Diagram Blok Klasifikasi EEG

2.1 Dataset

Bonn University dataset digunakan pada penelitian ini, terdiri dari lima subset dengan masing-masing subset berisi 100 segmen sinyal EEG. Setiap segmen direkam selama 23,6 detik menggunakan sistem penguat dengan 128 saluran, pada laju pengambilan sampel sebesar 173,61 Hz, serta disaring menggunakan bandpass filter dengan rentang frekuensi 0,53-40 Hz. Setiap segmen data ini menghasilkan rangkaian waktu sepanjang 4097 titik data (Abbasi et al., 2019).

Kelima subset EEG tersebut pada Gambar 2 mewakili lima kelas yang berbeda, Set A dan Set B direkam dari kulit kepala lima subjek sehat, masing-masing dengan kondisi mata terbuka dan mata tertutup. Set C, Set D, dan Set E direkam dari lima subjek yang menderita epilepsi. Set C dan Set D diambil dari zona epileptogenik dan pembentukan hippocampus di belahan otak yang berlawanan, keduanya direkam selama interval bebas kejang (interictal). Sementara itu, Set E direkam selama aktivitas kejang (ictal).



Gambar 2. Masing-Masing Subset Bonn EEG

2.2 Prapemrosesan Data

Pada penelitian ini, prapemrosesan data terdiri dari beberapa tahapan, yaitu segmentasi sinyal, pemisahan komponen independen menggunakan *Independent Component Analysis* (ICA), dan normalisasi menggunakan Z-score.

Kinerja model *deep learning* bergantung pada jumlah data yang banyak (Shanmugam & Dharmar,

2023). Penelitian ini menggunakan menggunakan teknik segmentasi jendela tumpang tindih (*overlapped sliding window*) untuk membagi Sinyal EEG yang Panjang menjadi segmen-segmen yang lebih pendek guna menambah jumlah sampel data EEG. Sinyal dibagi menjadi 24 segmen, dengan rata-rata 174 sampel pada setiap segmennya. Jadi masing-masing subset memiliki total 2.400 observasi, dan secara keseluruhan terdapat 12.000 observasi yang terkumpul dalam lima set. Kemudian proses selanjutnya adalah dekomposisi sinyal dengan menggunakan *library* sklearn FastICA. Setelah melakukan pemisahan komponen independen, dilakukan proses normalisasi data menggunakan Z-score untuk membantu menjaga konsistensi skala antar-segmen. Pada rumus 1 Z adalah data yang telah dinormalisasi, X adalah data hasil dari proses ICA, μ adalah rata-rata dari data tersebut, dan σ adalah standar deviasinya. Tabel 1 menampilkan jumlah sampel yang dihasilkan dari prapemrosesan.

$$Z = \frac{x - \mu}{\sigma} \quad (1)$$

Tabel 1. Jumlah Sampel EEG Dalam Setiap Set

Dataset	Set A	Set B	Set C	Set D	Set E
Bonn University	2400	2400	2400	2400	2400

2.3 Augmentasi Data

Augmentasi data dilakukan pada data EEG untuk meningkatkan variasi data pelatihan tanpa mengubah pola utama sinyal, guna mengurangi risiko *overfitting* dan meningkatkan kemampuan model dalam generalisasi (Ullah et al., 2018). Teknik yang digunakan adalah *Cubic Spline Interpolation* (CSI), metode yang digunakan untuk membangun kurva halus yang melewati serangkaian titik data (x_i, y_i) dengan menjaga kontinuitas hingga turunan kedua (Pedram et al., 2023). Setiap segmen antara dua titik data didefinisikan oleh polinomial kubik rumus 2. Untuk menghasilkan kurva yang halus, turunan pertama rumus 3 dan turunan kedua rumus 4 dari polinomial didefinisikan sebagai berikut:


$$C_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3 \quad (2)$$

$$C'_i(x) = b_i + 2c_i(x - x_i) + 3d_i(x - x_i)^2 \quad (3)$$

$$C''_i(x) = 2c_i(x - x_i) + 6d_i(x - x_i) \quad (4)$$

Metode cubic spline memastikan kontinuitas pada setiap titik data (x_i) , sehingga fungsi, turunan pertama, dan turunan kedua memenuhi hubungan $C_i(x_i) = y_i$, $C'_i(x_i) = C'_{i+1}(x_i)$, $C''_i(x_i) = C''_{i+1}(x_i)$. Untuk menghitung koefisien a_i , b_i , c_i , d_i sitem persamaan linear dibangun berdasarkan kondisi tersebut serta kondisi batas (*boundary conditions*), seperti *natural boundary* (turunan kedua di ujung-ujung kurva sama dengan nol) atau *clamped*

boundary (turunan pertama diketahui di kedua



Gambar 1. Arsitektur LSTM

ujung). Augmentasi ini penting karena sinyal EEG bersifat dinamis, terutama pada kondisi yang berhubungan dengan kejang, dan CSI membantu menangani variasi tersebut dengan menambah keragaman data yang digunakan selama pelatihan jaringan.

2.4 Convolutional Neural Network (CNN)

CNN yang diusulkan ini terdiri dari tiga lapisan konvolusi (conv layer) yang berurutan (64,192,256), masing-masing layer diikuti oleh fungsi aktivasi ReLU dan Batch Normalization. Kemudian melalui lapisan pooling, dimensi fitur dikurangi untuk menghindari *overfitting* dengan tetap menjaga skala fitur tidak berubah. CNN memungkinkan untuk mengekstrak fitur secara otomatis melalui conv layer (Reddy & Suchetha, 2022). Selain itu dengan karakteristik back-propagation-nya, CNN dapat memberi umpan balik dengan lebih baik.

Fungsi aktivasi ReLU rumus 5 dan *Batch Normalization* (BN) rumus 6 diterapkan untuk mempercepat proses pelatihan (Roy & Islam, 2020). Dengan menerapkan BN untuk menormalkan *output* dari lapisan konvolusi, distribusi *output* menjadi lebih stabil, dan membantu dalam mencegah *overfitting*. x_i adalah input dari *mini-batch*, μ_B dan σ_B masing-masing adalah rata-rata dan variansi dari *mini-batch* B , γ dan β adalah parameter skala dan pergeseran.

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

$$BN_{\gamma, \beta}(x_i) = \gamma \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta \quad (6)$$

Karakteristik data sinyal EEG berupa deret waktu dengan korelasi yang kuat tidak dapat diabaikan. Dalam suatu periode tertentu, memiliki nilai yang penting untuk melakukan klasifikasi kejang epilepsi.

2.5 Bidirectional Long Short-Term Memory (Bi-LSTM)

Bi-LSTM adalah sebuah model *deep learning* yang memiliki dua buah jaringan *Long Short-Term Memory* (LSTM) dengan arah yang berbeda. Kedua jaringan ini terhubung ke *output layer* yang sama untuk menghasilkan informasi keluaran (Yildirim,

2018). Proses informasi LSTM mengikuti serangkaian langkah untuk mengelola dan mempertahankan informasi penting pada setiap langkah waktu. Gambar 3 menunjukkan arsitektur LSTM.

Pada setiap waktu t , LSTM menerima input x_t dan *hidden state* sebelumnya h_{t-1} . Pertama, *forget gate* f_t rumus 7 memutuskan seberapa banyak informasi dari *cell state* sebelumnya C_{t-1} yang perlu dihapus. Selanjutnya, *input gate* i_t rumus 8 menentukan informasi baru yang akan disimpan ke dalam *cell state* melalui perhitungan kandidat *cell state* $\tilde{C}_t$ rumus 9. Setelah itu, *cell state* diperbarui dengan mengombinasikan informasi dari *forget gate* dan *input gate*, menghasilkan *cell state* baru C_t rumus 10. Kemudian, *output gate* O_t rumus 11 mengontrol informasi yang akan dihasilkan sebagai *hidden state* baru h_t rumus 12 yang diteruskan ke langkah berikutnya.

$$f_t = \sigma(W_f h_{t-1} + W_{fx} x_t + b_f) \quad (7)$$

$$i_t = \sigma(W_{ih} h_{t-1} + W_{ix} x_t + b_i) \quad (8)$$


$$\tilde{C}_t = \tanh(W_{ch} h_{t-1} + W_{cx} x_t + b_c) \quad (9)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (10)$$

$$O_t = \sigma(W_{oh} h_{t-1} + W_{ox} x_t + b_o) \quad (11)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (12)$$


Pada Bi-LSTM kedua jaringan LSTM terhubung ke *output layer* yang sama untuk menghasilkan informasi keluaran. Pada arah maju, data diproses dari waktu $t = 1$ hingga $t = T$, sedangkan pada arah mundur, data diproses dari waktu $t = T$ kembali ke waktu $t = 1$. Bi-LSTM pada Gambar 4 memungkinkan mengevaluasi proses masa lalu dan masa depan dalam waktu bersamaan. *Dropout* dan *GlorotUniform* digunakan pada *layer* Bi-LSTM, kombinasi keduanya membantu model Bi-LSTM menjadi lebih stabil, menghindari masalah *overfitting*, dan meningkatkan kemampuan model dalam memahami pola temporal sinyal EEG untuk klasifikasi *multiclass*.



Gambar 4. Arsitektur Bi-LSTM

Model CNN-Bi-LSTM yang diusulkan terdiri dari lapisan ekstraksi fitur dan lapisan pembelajaran

Gambar 5. CNN dalam arsitektur ini secara otomatis mengekstrak fitur spasial dari sinyal EEG mentah, seperti pola frekuensi dan amplitudo yang sering kali tidak terlihat secara kasat mata, tanpa memerlukan prapemrosesan yang rumit atau pemahaman domain yang mendalam. Kemudian, Bi-LSTM berperan dalam memahami hubungan temporal di dalam sinyal, memproses pola-pola untuk menangkap keterkaitan temporal yang kompleks antar segmen sinyal. Hal ini memungkinkan model untuk menyimpan informasi dari periode waktu sebelumnya dan setelahnya dalam sinyal, yang penting untuk klasifikasi multi kelas, terutama ketika pola kejang mungkin terbentuk melalui kombinasi urutan sinyal yang berhubungan dengan aktivitas otak sebelum, saat, dan setelah kejang.



Gambar 5. Arsitektur CNN+Bi-LSTM

2.6 Model Evaluasi

Model Evaluasi yang digunakan pada penelitian adalah dengan menghitung data pengujian untuk setiap tugas klasifikasi.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \times 100 \quad (13)$$

$$Sensitivity = \frac{TP}{TP + FN} \times 100 \quad (14)$$

$$Specificity = \frac{TN}{TN + FP} \times 100 \quad (15)$$

Di mana TP adalah true positive, TN adalah true negative, FP adalah false positif dan FN adalah false negative.

3. PEMBAHASAN

3.1 Pengujian dan Evaluasi

Pada proses pengujian dan evaluasi sistem, data EEG yang telah diproses dibagi menjadi dua tugas klasifikasi (A/D/E dan B/D/E) dengan tujuan mengidentifikasi kondisi normal, interictal, dan ictal. Teknik *Cubic Spline Interpolation* (CSI) digunakan sebagai metode untuk menghasilkan sampel tambahan selama pelatihan jaringan karena sifat non-linear dari sinyal EEG dan perilaku dinamisnya yang nyata dari waktu ke waktu, terutama pada sinyal yang berhubungan dengan kejang. Setelah augmentasi, data dibagi menjadi set pelatihan dan pengujian dengan rasio 80:20, di mana 80% data digunakan untuk pelatihan dan 20% untuk pengujian.

Pada tugas klasifikasi A/D/E, jumlah total sampel setelah augmentasi mencapai 43.200 sampel, dengan 34.560 sampel digunakan untuk pelatihan dan 8.640 sampel untuk pengujian. Sementara itu, pada

tugas klasifikasi B/D/E, jumlah total sampel juga mencapai 43.200 sampel, dengan pembagian yang sama: 34.560 sampel untuk pelatihan dan 8.640 sampel untuk pengujian. Atribut yang digunakan adalah nilai amplitudo sinyal EEG yang diambil dari 174 titik data temporal. Setiap sampel sinyal EEG diwakili sebagai array berdimensi (174, 1), yang menggambarkan amplitudo pada 174 titik waktu yang berbeda.

Pada proses pelatihan, model memanfaatkan *optimizer* Nadam dengan *learning rate* tetap sebesar 0.0001. Selain itu, mekanisme *early stopping* diterapkan untuk menghentikan pelatihan jika tidak ada perbaikan signifikan pada *validation loss* selama 20 epoch berturut-turut, dengan maksimal pelatihan hingga 100 epoch. Dalam skenario ini, 2 data (asli dan augmentasi) akan digunakan untuk melatih dan menguji pada model yang diusulkan. Proses pengujian menggunakan set data pengujian yang sama dalam kedua skenario. Pendekatan ini memastikan bahwa hasil pengujian mencerminkan perbedaan kinerja model berdasarkan pelatihan dengan data asli atau augmentasi. Kinerja model dievaluasi berdasarkan *Accuracy*, *Sensitivity*, dan *Specificity* rumus 13 – 15.

3.2 Hasil

Metode yang diusulkan divalidasi menggunakan tugas klasifikasi tiga kelas, yaitu normal, interictal, dan ictal, untuk mengidentifikasi kondisi pasien berdasarkan sinyal EEG. Evaluasi dilakukan pada dua skenario data, yaitu data asli dan data augmentasi, untuk dua kombinasi subset data, yaitu (A/D/E) dan (B/D/E). Hasil kinerja dievaluasi dengan metrik utama seperti *Accuracy*, *Sensitivity*, dan *Specificity*, yang kemudian dirangkum dalam Tabel 2 sebagai perbandingan kinerja model yang diusulkan pada setiap jenis data dan subset. Untuk mendapatkan perspektif yang lebih lengkap mengenai keunggulan model, Tabel 3 membandingkan kinerja metode yang diusulkan dengan penelitian sebelumnya yang menggunakan set data yang sama. Melalui tabel ini, dapat terlihat sejauh mana metode yang diusulkan meningkatkan performa klasifikasi dibandingkan dengan pendekatan yang telah ada.

Model CNN+Bi-LSTM diuji pada data asli untuk kedua tugas klasifikasi A/D/E dan B/D/E. Hasil pengujian pada data A/D/E mencapai *Accuracy* 95.07%. Model cukup baik dalam mengenali pola, namun terdapat kemungkinan *overfitting* karena akurasi pelatihan yang jauh lebih tinggi. Pada data B/D/E model mampu mencapai *Accuracy* 97.85%. Kemudian model CNN+Bi-LSTM diuji pada data yang telah diaugmentasi. Hasil pengujian pada data A/D/E mampu mencapai *Accuracy* 99.50% dan hasil pengujian pada data B/D/E model mampu mencapai *Accuracy* 99.87%.

Tabel 2. Hasil Kinerja Model CNN+Bi-LSTM Yang Diusulkan

<i>Classification Task</i>	<i>Spec.</i>	<i>Sens.</i>	<i>Accu.</i>
A/D/E Data Asli	95.07%	95.06%	95.07%
A/D/E Data Augmentasi	99.50%	99.50%	99.50%
B/D/E Data Asli	97.85%	97.84%	97.85%
B/D/E Data Augmentasi	99.87%	99.87%	99.87%

Tabel 3. Perbandingan Antara Metode yang Diusulkan Dengan Model Lain yang Menggunakan Dataset yang Sama

Penulis	Data Sub Set	Data Selection	Acc.
(Mamun Or Rashid & Ahmad, 2017)	A/D/E	70/30	80.0%
(Ahmed M. et al., 2023)	A/D/E	10-Fold	98.66%
Metode yang diusulkan	A/D/E	80/20	99.50%
(Mamun Or Rashid & Ahmad, 2017)	B/D/E	70/30	79.3%
(Ahmed M. et al., 2023)	B/D/E	10-Fold	98.89%
Metode yang diusulkan	B/D/E	80/20	99.87%

4. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa model CNN-BiLSTM efektif dalam mengatasi tantangan klasifikasi kejang epilepsi *multiclass* pada sinyal EEG. Keberhasilan klasifikasi model dalam membedakan periode EEG normal, interictal, dan ictal menjadi aspek penting yang membantu dalam menentukan jenis dan tingkat keparahan kejang, serta penentuan pengobatan yang lebih tepat. Model ini mencapai akurasi tertinggi sebesar 99.87% pada tugas klasifikasi B/D/E menggunakan data augmentasi, yang menunjukkan keunggulan dalam pengenalan pola kejang epilepsi.

Kompleksitas sinyal EEG, yang sering kali sulit dianalisis, diatasi melalui segmentasi sinyal ke dalam potongan yang lebih pendek. Hal ini membantu model dalam menangkap pola-pola halus yang sulit diamati. Selain itu, proses prapemrosesan, termasuk pemisahan komponen independen dan normalisasi dengan Z-score, meningkatkan stabilitas model dalam melakukan klasifikasi sinyal EEG secara akurat. Penggunaan augmentasi data terbukti efektif dengan akurasi yang meningkat dari 95.07% menjadi 99.50% pada klasifikasi A/D/E dan dari 97.85% menjadi 99.87% pada klasifikasi B/D/E. Secara

keseluruhan, penerapan model CNN-BiLSTM yang diusulkan tidak hanya mampu meningkatkan akurasi deteksi kejang epilepsi, tetapi juga memberikan solusi efisien dalam klasifikasi sinyal EEG multiclass.

Namun, terdapat beberapa limitasi dalam penelitian ini. Pertama, meskipun model mencapai akurasi yang sangat tinggi, performa model dapat bervariasi pada dataset yang lebih besar atau berbeda. Kedua, proses prapemrosesan seperti segmentasi dan augmentasi data dapat mempengaruhi efisiensi model dalam aplikasi waktu nyata, mengingat adanya kebutuhan komputasi yang cukup tinggi. Selain itu, model ini mungkin belum sepenuhnya optimal dalam menangani variasi yang sangat besar pada sinyal EEG dari berbagai individu. Untuk itu, pengujian lebih lanjut dengan data yang lebih beragam dan pengoptimalan lebih lanjut diperlukan untuk memperkuat aplikasi klinis model ini.

Dengan hasil ini, metode yang dikembangkan memiliki potensi untuk membantu proses diagnosis epilepsi secara otomatis di lingkungan klinis. Studi lebih lanjut dan evaluasi klinis di berbagai kondisi sangat diperlukan untuk memastikan keandalannya dalam praktik medis.

PUSTAKA

- Abbasi, M. U., Rashad, A., Basalamah, A., & Tariq, M. (2019). Detection of Epilepsy Seizures in Neo-Natal EEG Using LSTM Architecture. *IEEE Access*, 7, 179074–179085. <https://doi.org/10.1109/ACCESS.2019.2959234>
- Ahmed M., A., Hisham G., D., & Magdy, B. (2023). Deep Convolutional Bidirectional LSTM Recurrent Neural Network for Epileptic Seizure Detection. *International Conference on Telecommunications and Signal Processing (TSP)*.
- Eviyanti, A., Saikhu, A., & Fatichah, C. (2022). Epileptic Seizure Detection Using Machine Learning and Deep Learning Method. *Proceedings - 2022 IEEE International Conference on Cybernetics and Computational Intelligence, CyberneticsCom 2022*, 463–468. <https://doi.org/10.1109/CyberneticsCom55287.2022.9865313>
- Mamun Or Rashid, M., & Ahmad, M. (2017). Epileptic Seizure Classification using Statistical Features of EEG Signal. *International Conference on Electrical, Computer and Communication Engineering (ECCE)*.
- Manasvi Bhat, K., Pratiksha P, A., Yashashree, S., Sanjeetha, R., & Anita, K. (2019). Detection and Prediction of the Preictal State of an Epileptic Seizure using Machine Learning Techniques on EEG Data. *Bombay Section Signature Conference*.
- Nanthini, K., Tamilarasi, A., Pyingkodi, M., Dishanthi, M., Kaviya, S. M., & Mohideen, P. A. (2022). Epileptic Seizure Detection and Prediction Using Deep Learning Technique. *2022 International Conference on Computer Communication and Informatics, ICCCI 2022*. <https://doi.org/10.1109/ICCCI54379.2022.9740802>
- Oliva, J. T., & Rosa, J. L. G. (2021). Binary and multiclass classifiers based on multitaper spectral features for epilepsy detection. *Biomedical Signal Processing and Control*, 66. <https://doi.org/10.1016/j.bspc.2021.102469>
- Pedram, R., Farzanehkari, P., & Chaibakhsh, A. (2023). Enhancing Epileptic Seizure Detection Using Convolutional Neural Networks and Data Augmentation Techniques. *2023 30th National and 8th International Iranian Conference on Biomedical Engineering, ICBME 2023*, 132–137. <https://doi.org/10.1109/ICBME61513.2023.10488640>
- Reddy, S. K. C., & Suchetha, M. (2022). A 1-D CNN-FSVM Model with a multi-scale sub-band feature learning for automated seizure detection. *Proceedings - IEEE International Conference on Advances in Computing, Communication and Applied Informatics, ACCAI 2022*. <https://doi.org/10.1109/ACCAI53970.2022.9752500>
- Rohan, T. I., Yusuf, Md. S. U., Islam, M., & Roy, S. (2020). Efficient Approach to Detect Epileptic Seizure using Machine Learning Models for Modern Healthcare System. *Region 10 Symposium (TENSYP)*.
- Roy, A. D., & Islam, M. M. (2020, December 19). Detection of Epileptic Seizures from Wavelet Scalogram of EEG Signal Using Transfer Learning with AlexNet Convolutional Neural Network. *ICCIT 2020 - 23rd International Conference on Computer and Information Technology, Proceedings*. <https://doi.org/10.1109/ICCIT51783.2020.9392720>
- Shakeel, S., Afzal, N., Khan, G. H., Khan, N. A., Abid, M. U. R., & Altaf, M. A. Bin. (2021). EDM: A multiclassification support system to identify seizure type using K Nearest Neighbor. *2021 28th IEEE International Conference on Electronics, Circuits, and Systems, ICECS 2021 - Proceedings*. <https://doi.org/10.1109/ICECS53924.2021.9665565>
- Shanmugam, S., & Dharmar, S. (2023). A CNN-LSTM hybrid network for automatic seizure detection in EEG signals. *Neural Computing*

- and Applications*, 35(28), 20605–20617.
<https://doi.org/10.1007/s00521-023-08832-2>
- Tales Oliva, J., Luís Garcia Rosa, J., Carlos, S., Paulo, S., & Senior Member, B. (2019). Epilepsy detection using multiclass classifier based on spectral features. *International Joint Conference on Neural Networks*.
<http://epileptologie-bonn.de/cms/front>
- Yildirim, Ö. (2018). A novel wavelet sequences based on deep bidirectional LSTM network model for ECG signal classification. *Computers in Biology and Medicine*, 96, 189–202.
<https://doi.org/10.1016/j.compbiomed.2018.03.016>

HALAMAN INI SENGAJA DIKOSONGKAN