

Deteksi Prakejang Pada Pasien Epilepsi Berdasarkan Rekam Sinyal EEG Menggunakan Metode LSTM

Ade Eviyanti¹, Arif Senja Fitriani², Umi khoirun Nisak³, Erlina Agustin⁴, Aldy Trisza Zahputra⁵

^{1,2,4,5} Prodi informatika, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Sidoarjo, Indonesia

³ Prodi Manajemen Informasi Kesehatan, Fakultas Kesehatan, Universitas Muhammadiyah Sidoarjo, Indonesia

Email: adeeviyanti@umsida.ac.id

Abstract. Epilepsy is a non-communicable brain disorder that affects approximately 50 million people worldwide. Electroencephalogram (EEG) signals provide crucial information about brain electrical activity. Epilepsy can be detected through EEG signal analysis, but the process is complex, requires human expertise, and is time-consuming. Pre-seizure detection in epilepsy patients poses a challenge in the field of neurology. In this research, we focus on developing a pre-seizure detection method using EEG signals and employing the Long Short-Term Memory (LSTM) approach. EEG signals are recorded from epilepsy patients during specific periods, and then processed and analyzed using the LSTM method. LSTM is a type of recurrent neural network (RNN) known for its ability to model and learn from sequential data. The LSTM approach enables better modeling of dynamic EEG signal characteristics, including patterns before a seizure occurs. In this study, we used an EEG signal dataset comprising epilepsy patients with and without seizures. The data was divided into training and testing sets to train and evaluate the LSTM model. The model training process was performed by optimizing parameters and adjusting LSTM network weights based on the training data. Experimental results demonstrate that the LSTM method can detect seizures in epilepsy patients with an accuracy level of 98.44% using the RMSprop optimizer. This research contributes to the development of pre-seizure detection techniques in epilepsy patients using EEG signals and the LSTM method. The findings of this study can serve as a foundation for further advancements in seizure detection systems.

Keywords : Pre-seizure detection, Epilepsy patients, EEG signals, LSTM, Signal analysis

Abstrak. Epilepsi adalah penyakit otak yang tidak menular dan memengaruhi sekitar 50 juta orang di dunia. Sinyal *electroencephalogram* (EEG) memberikan informasi penting tentang aktivitas listrik otak. Epilepsi bisa terdeteksi melalui analisis sinyal EEG, tetapi prosesnya rumit, membutuhkan keterampilan manusia, dan memakan waktu. Deteksi pracejang pada pasien epilepsi merupakan tantangan dalam bidang neurologi. Dalam penelitian ini, kami memfokuskan pada pengembangan metode deteksi pracejang menggunakan sinyal EEG dan menggunakan pendekatan metode Long Short-Term Memory (LSTM). Dalam analisisnya. Sinyal EEG direkam dari pasien epilepsi selama periode tertentu, dan kemudian dilakukan pemrosesan dan analisis menggunakan metode LSTM. LSTM adalah jenis jaringan saraf rekuren (RNN) yang terkenal karena kemampuannya dalam memodelkan dan mempelajari urutan data. Pendekatan LSTM memungkinkan pemodelan yang lebih baik terhadap karakteristik dinamis sinyal EEG, termasuk pola sebelum terjadinya pracejang. Dalam penelitian ini, kami menggunakan dataset sinyal EEG yang terdiri dari pasien epilepsi dengan pracejang dan tanpa pracejang. Data tersebut dibagi menjadi set pelatihan dan set pengujian untuk melatih dan menguji model LSTM. Proses pelatihan model dilakukan dengan mengoptimalkan parameter dan menyesuaikan bobot jaringan LSTM berdasarkan data pelatihan. Hasil eksperimen menunjukkan bahwa metode LSTM mampu mendeteksi pracejang pada pasien epilepsi dengan tingkat akurasi 98.44% dengan menggunakan optimizer RMSprop. Penelitian ini

memberikan kontribusi dalam pengembangan teknik deteksi prakejang pada pasien epilepsi menggunakan sinyal EEG dan metode LSTM. Hasil-hasil penelitian ini dapat digunakan sebagai dasar untuk pengembangan sistem deteksi prakejang yang lebih lanjut.

Kata Kunci: *Deteksi prakejang, Pasien epilepsi, Sinyal EEG, LSTM, Analisis sinyal*

1. Pendahuluan

Epilepsi adalah kondisi neurologis kronis yang tidak menular yang memengaruhi sekitar 50 juta orang di seluruh dunia. Prevalensi epilepsi aktif dalam populasi umum, yang ditandai dengan kejang berulang atau kebutuhan akan pengobatan, berkisar antara 4 hingga 10 per 1000 orang. Individu yang menderita epilepsi sering menghadapi berbagai komplikasi fisik, seperti patah tulang dan cedera akibat kejang, serta berisiko lebih tinggi mengalami gangguan psikologis, termasuk kecemasan dan depresi (Djoufack Nkengfack et al., 2021). Oleh karena itu, deteksi dan prediksi kejang menjadi aspek krusial dalam pengelolaan epilepsi, terutama untuk meningkatkan kualitas hidup pasien dan mengurangi risiko komplikasi serius.

Seiring dengan berkembangnya teknologi, kecerdasan buatan (AI) telah memungkinkan sistem untuk mengolah, menganalisis, dan menginterpretasikan data secara lebih efisien dan akurat. Penerapan AI dalam pemrosesan data dan analisis pola telah meningkatkan performa berbagai teknologi, termasuk dalam sistem prediksi dan klasifikasi berbasis machine learning dan deep learning. Dalam konteks epilepsi, AI berperan penting dalam mengidentifikasi pola dalam sinyal EEG untuk mendeteksi prakejang dengan tingkat akurasi yang lebih tinggi. Dengan kemampuannya menangani big data dan pola sekuensial, AI telah menjadi teknologi kunci dalam inovasi di berbagai sektor (Jamaluddin et al., 2023), termasuk kesehatan, yang memungkinkan pengembangan sistem deteksi prakejang berbasis Long Short-Term Memory (LSTM) dan energi terbarukan sebagai solusi yang lebih adaptif dan cerdas (Jamaaluddin et al., 2024)

Salah satu tantangan utama dalam analisis epilepsi adalah mendeteksi dan meramalkan kejang secara akurat. Untuk mencapai tujuan tersebut, diperlukan metode yang dapat membedakan pola sinyal antara kondisi kejang dan non-kejang. Berbagai pendekatan telah dikembangkan untuk meningkatkan akurasi deteksi, untuk mengatasi keterbatasan dalam teknik machine learning tradisional, yakni menggunakan algoritma *deep learning* (DL) dalam sistem deteksi epilepsi otomatis. Berbeda dengan metode konvensional yang memerlukan ekstraksi fitur secara manual, DL memiliki arsitektur berlapis-lapis yang memungkinkan sistem memproses dataset berukuran besar, menangani ketidakseimbangan data, serta menghasilkan prediksi yang lebih akurat tanpa bias terhadap kelas mayoritas. Dalam sistem deteksi epilepsi, para ahli telah menerapkan beberapa arsitektur deep learning, seperti *LSTM networks*, *Convolutional Neural Networks* (CNNs), dan *Gated Recurrent Units* (GRUs), untuk meningkatkan akurasi dan efisiensi dalam mendeteksi pola kejang secara otomatis (Saminu et al., 2021).

Dalam upaya mendeteksi kejang epilepsi, sinyal Electroencephalogram (EEG) telah banyak digunakan karena kemampuannya dalam merekam aktivitas listrik otak. EEG memberikan informasi yang penting untuk mendiagnosis dan memantau pasien epilepsi. Namun, analisis sinyal EEG sering kali kompleks dan membutuhkan tingkat keahlian manusia yang tinggi untuk interpretasi yang akurat (Harpale & Bairagi, 2018) Oleh karena itu, pendekatan berbasis kecerdasan buatan telah diperkenalkan untuk meningkatkan efisiensi dalam analisis sinyal EEG.

Transformasi sinyal EEG menjadi model berbasis komputasi telah menjadi strategi yang efektif dalam proses klasifikasi, identifikasi, dan estimasi spektrum sinyal EEG. Deteksi dan pengenalan pola dalam sinyal EEG menjadi langkah kritis dalam mendiagnosis epilepsi (Zhou & Li, 2020). Salah satu pendekatan yang semakin populer dalam analisis sinyal EEG adalah deep learning, yang menerapkan jaringan saraf tiruan untuk mengidentifikasi pola yang kompleks dalam data. Perkembangan teknologi ini telah memberikan kemajuan signifikan dalam berbagai bidang, termasuk analisis medis (Mohanty et al., 2021).

Dalam konteks deteksi epilepsi, deteksi otomatis kejang epilepsi berbasis deep learning semakin mendapat perhatian, namun potensi jaringan saraf dalam deteksi kejang masih belum sepenuhnya dimanfaatkan, terutama dalam desain arsitektur model yang optimal serta efektivitas

deteksi data otak berbasis time-series. Penelitian ini memperkenalkan arsitektur deep neural network yang mampu mempelajari ketergantungan temporal dalam data *electroencephalogram* (EEG) untuk mendeteksi kejang epilepsi secara lebih andal. Metode yang digunakan melibatkan *Long Short-Term Memory* (LSTM) untuk mempelajari representasi tingkat tinggi dari pola EEG, yang kemudian diekstraksi oleh lapisan *Fully Connected* (FC) guna mendapatkan fitur EEG paling relevan terhadap kejang epilepsi. Hasil klasifikasi ditentukan melalui lapisan softmax, yang menghasilkan label prediksi. Uji coba pada dataset klinis benchmark menunjukkan keunggulan pendekatan ini dibandingkan teknik dasar lainnya, dengan mencapai akurasi, sensitivitas, dan spesifisitas 100% (Hussein et al., 2019).

Seiring berkembangnya metode kecerdasan buatan, berbagai teknik prapemrosesan dan model klasifikasi telah diterapkan dalam deteksi epilepsi guna meningkatkan akurasi prediksi kejang. Sebuah uji coba dilakukan dengan memanfaatkan data EEG dari 10 pasien yang dipilih berdasarkan 22 channel EEG yang sama. Hasil penelitian menunjukkan bahwa model k-Nearest Neighbors (k-NN) yang digunakan sebagai pengklasifikasi berhasil mencapai tingkat akurasi sebesar 91% (Page et al., 2015). Selanjutnya, metode Discrete Wavelet Transform (DWT) diperkenalkan untuk mengekstraksi fitur temporal, seperti nilai minimum, rata-rata, dan standar deviasi. Fitur-fitur ini kemudian diterapkan pada empat model klasifikasi tradisional: Support Vector Machine (SVM), k-NN, Random Forest (RF), dan Decision Tree (DT). Uji coba yang dilakukan pada lima pasien dengan 23 channel EEG menunjukkan akurasi masing-masing model sebagai berikut: SVM: 81,34%, k-NN: 91,09%, RF: 90,60%, dan DT: 87,60% (Qureshi et al., 2021).

Untuk meningkatkan kualitas deteksi, penelitian lain memanfaatkan teknik pemrosesan sinyal EEG yang lebih canggih. Data EEG diproses menggunakan Butterworth Band-Pass Filter dan DWT untuk meningkatkan resolusi spasial serta mengurangi noise. Selain itu, fitur sinyal EEG diekstraksi menggunakan Power Spectral Density (PSD), dan seleksi fitur dilakukan dengan *Mutual Information* (MI) untuk meningkatkan keakuratan klasifikasi. Dengan metode Naïve Bayes (NB) dan k-NN, penelitian ini mencapai tingkat akurasi hingga 100% (Sharmila, 2018).

Pendekatan inovatif dalam deteksi kejang epilepsi berbasis EEG dikembangkan dengan menerapkan sistem pembelajaran terawasi untuk meningkatkan akurasi klasifikasi secara otomatis. Data EEG dari Temple University Hospital (TUH), Bern–Barcelona EEG (BB-EEG), Bonn University EEG (BU-EEG), dan dataset simulasi diproses menggunakan *fast Empirical mode decomposition* (FEMD) untuk mengekstraksi fitur entropi, frekuensi, *auto-regresif*, dan statistik. Pendekatan *reliefF* diterapkan untuk mengurangi dimensionalitas data, sementara LSTM digunakan sebagai klasifikator terawasi. Hasil eksperimen menunjukkan bahwa metode ini meningkatkan akurasi klasifikasi kejang hingga 0,6–16% dibandingkan teknik sebelumnya, membuktikan bahwa LSTM dan ekstraksi fitur adaptif dapat meningkatkan efisiensi deteksi kejang epilepsi dan menjadi solusi potensial dalam diagnosis berbasis EEG (Dwaraka et al., 2020).

Keterbatasan efektivitas pengobatan pada pasien epilepsi yang mengalami kejang parah menjadikan epilepsi sebagai salah satu penyakit otak yang berpotensi mengancam jiwa. Oleh karena itu, diperlukan alat dan metode deteksi serta prediksi kejang yang lebih akurat. Salah satu metodologi yang komprehensif dalam deteksi kejang otomatis adalah DWT, yang memungkinkan dekomposisi sinyal EEG dalam lima level serta ekstraksi lima fitur utama dari koefisien wavelet. Fitur-fitur ini kemudian digunakan dalam model Random Forest (RF) untuk membedakan antara kondisi kejang dan non-kejang, dengan akurasi klasifikasi melebihi 95% (Tzimourta et al., 2018).

Dalam penelitian ini, kami fokus pada pengembangan metode deteksi prakejang menggunakan sinyal EEG dengan menerapkan pendekatan *Long Short-Term Memory* (LSTM). LSTM merupakan jenis jaringan saraf rekuren (*Recurrent Neural Network/RNN*) yang terkenal karena kemampuannya dalam mempelajari pola urutan data. Dengan memanfaatkan metode ini, penelitian bertujuan untuk meningkatkan akurasi dan keandalan dalam mendeteksi prakejang pada pasien epilepsi.

Penelitian sebelumnya telah menunjukkan bahwa metode LSTM memiliki potensi besar dalam analisis sinyal EEG untuk deteksi kejang epilepsi. Namun, masih terdapat tantangan terkait

sifat sinyal EEG yang tidak terduga dan fluktuatif. Oleh karena itu, penelitian ini berusaha untuk mengatasi kendala tersebut dengan mengembangkan metode deteksi prakejang yang lebih efektif dan akurat.

Artikel ini akan membahas secara rinci pendekatan yang digunakan dalam mendeteksi prakejang pada pasien epilepsi berdasarkan rekaman sinyal EEG dengan metode LSTM. Pembahasan meliputi langkah-langkah metodologi, pemrosesan data, serta evaluasi hasil eksperimen. Diharapkan bahwa penelitian ini dapat memberikan kontribusi signifikan dalam pengembangan teknik deteksi prakejang, yang pada akhirnya dapat membantu dalam pengawasan pasien epilepsi dan memberikan peringatan dini guna pengobatan yang lebih tepat waktu.

2. Tinjauan Pustaka

2.1. Epilepsi

Epilepsi adalah penyakit otak kronis yang tidak menular yang menyerang orang dari segala usia. Sekitar 50 juta orang di seluruh dunia menderita epilepsi, menjadikannya salah satu penyakit neurologis paling umum di dunia. Hampir 80% penderita epilepsi tinggal di negara berpenghasilan rendah dan menengah. Diperkirakan hingga 70% orang yang hidup dengan epilepsi dapat hidup bebas kejang jika didiagnosis dan diobati dengan benar. Risiko kematian dini pada orang dengan epilepsi hingga tiga kali lebih tinggi daripada populasi umum. Tiga perempat penderita epilepsi yang tinggal di negara berpenghasilan rendah tidak mendapatkan pengobatan yang mereka butuhkan. Perkiraan proporsi populasi umum dengan epilepsi aktif (yaitu kejang berkelanjutan atau dengan kebutuhan pengobatan) pada waktu tertentu adalah antara 4 dan 10 per 1000 orang. Secara global, diperkirakan lima juta orang didiagnosis dengan epilepsi setiap tahun. Di negara-negara berpenghasilan tinggi, diperkirakan ada 49 per 100.000 orang yang didiagnosis menderita epilepsi setiap tahun. Di negara-negara berpenghasilan rendah dan menengah, angka ini bisa mencapai 139 per 100.000 (Metzinger, 2016).

Episode kejang adalah akibat dari pelepasan listrik yang berlebihan pada sekelompok sel otak. Bagian otak yang berbeda dapat menjadi tempat pembuangan tersebut. Kejang dapat bervariasi dari penyimpangan perhatian atau sentakan otot yang singkat hingga kejang yang parah dan berkepanjangan. Satu kejang tidak menandakan epilepsi (hingga 10% orang di seluruh dunia mengalami satu kali kejang selama hidup mereka). Ketakutan, kesalahpahaman, diskriminasi dan stigma sosial telah melingkupi epilepsi selama berabad-abad. Stigma ini berlanjut di banyak negara saat ini dan dapat berdampak pada kualitas hidup orang dengan penyakit ini dan keluarganya (WHO, 2019).

2.2 Sinyal EEG

Electroencephalogram (EEG) adalah alat non-invasif yang digunakan untuk ekstraksi dan pemrosesan sinyal otak. Perilaku sinyal EEG yang acak dan tidak stasioner membuat prediksi kejang menjadi sulit. Jadi deteksi kejang dan prediksi merupakan isu yang sangat penting. Berbagai metode pemrosesan sinyal bersama dengan ekstraksi fitur disesuaikan untuk mengkategorikan segmen sinyal EEG menggunakan karakteristik spesifik dari sinyal (Harpale & Bairagi, 2018).

Sinyal EEG menyimpan informasi krusial mengenai aktivitas listrik yang terjadi di otak. Analisis terhadap sinyal ini memiliki peran penting dalam mendeteksi berbagai gangguan kesehatan, termasuk epilepsi. Namun, karakteristik sinyal EEG yang kompleks sering kali memerlukan keahlian khusus dalam proses interpretasinya. Secara konvensional, ahli saraf mengidentifikasi epilepsi dengan menganalisis aktivitas otak melalui pemeriksaan EEG. Pendekatan ini memiliki keterbatasan, karena rentan terhadap kesalahan serta memerlukan waktu yang cukup lama, mengingat sepenuhnya bergantung pada keterampilan manusia (Akut, 2019).

Transformasi sinyal EEG menjadi suatu model merupakan suatu cara yang sangat efektif dalam membantu proses klasifikasi, mengidentifikasi dan mengestimasi spektrum sinyal EEG. Sinyal EEG mengandung komponen-komponen tertentu yang dikenal sebagai gelombang alfa (8-

13 Hz), beta (14-30 Hz), teta (4-7 Hz), dan delta (0.5-3 Hz), Deteksi dan pengenalan sinyal EEG adalah cara yang paling penting untuk mendiagnosis epilepsi (Zhou & Li, 2020).

2.3 Deep Learning

Deep learning merupakan salah satu bidang yang menarik dan merupakan salah satu metode implementasi dari machine learning yang bertujuan meniru cara kerja otak manusia menggunakan jaringan syaraf tiruan. Jaringan syaraf tiruan sudah ada sejak lama tetapi perkembangannya mulai terjadi beberapa tahun terakhir. *Deep learning* dengan sejumlah algoritmanya akan bekerja dalam menentukan karakteristik-karakteristik tertentu pada suatu rangkaian data, dapat menangani dengan mudah berbagai domain masalah yang sulit karena biasanya menggunakan kapabilitas yang lebih kompleks dalam mempelajari dan mengklasifikasi data. Salah satu algoritma deep learning yang biasa digunakan adalah *Long Short-Term Memory* (LSTM,) yang merupakan suatu jenis arsitektur jaringan syaraf tiruan yang dapat digunakan untuk memprediksi suatu kejadian di masa depan berdasarkan data masa lalu (Jason Brownlee, 2021).

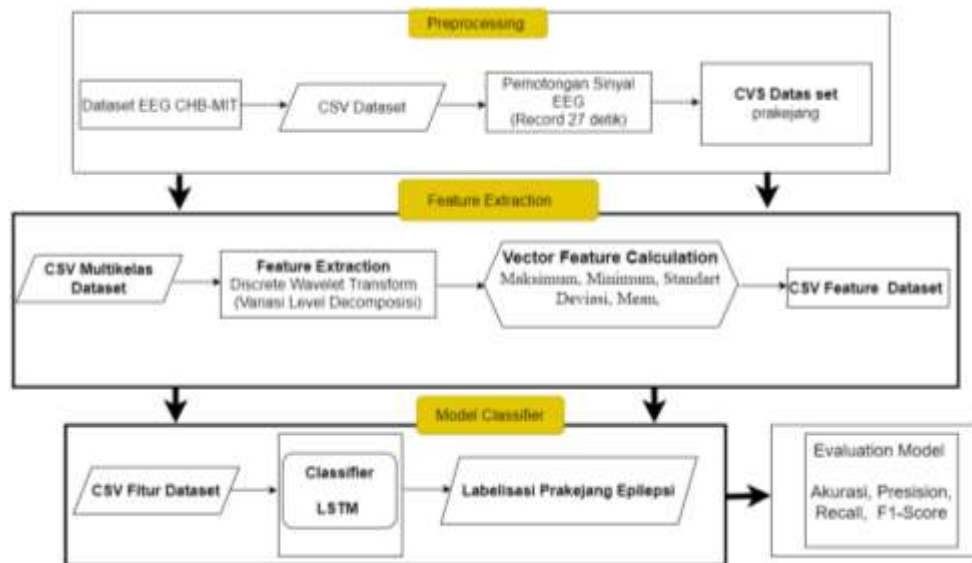
2.4. LSTM

Jaringan Long Short-Term Memory (LSTM) adalah jenis Recurrent Neural Network (RNN) yang dilatih menggunakan Backpropagation Through Time (BPTT) dan dirancang untuk mengatasi masalah vanishing gradient. Dengan kemampuannya ini, LSTM memungkinkan pembentukan jaringan berulang dalam skala besar (stacked RNN), yang dapat digunakan untuk menyelesaikan masalah sekuensial kompleks dalam pembelajaran mesin dan mencapai hasil mutakhir (state-of-the-art). Berbeda dengan RNN klasik yang menggunakan neuron biasa, LSTM terdiri dari blok memori (memory blocks) yang terhubung dalam lapisan jaringan, dengan komponen tambahan yang lebih kompleks dibandingkan neuron konvensional, termasuk memori untuk menyimpan informasi sekuensial terbaru (Jason Brownlee, 2021).

Setiap blok memiliki gerbang (gates) yang mengatur status dan output, di mana setiap unit LSTM memproses urutan input dengan menggunakan fungsi aktivasi sigmoid untuk menentukan apakah suatu gerbang akan diaktifkan atau tidak. Hal ini memungkinkan pengelolaan status dan penambahan informasi dalam unit secara kondisional. Dalam arsitekturnya, terdapat tiga jenis gerbang utama dalam unit memori LSTM, yaitu *forget gate* (Gerbang Lupa) yang mengatur informasi mana yang harus dibuang, *input gate* (Gerbang Masukan) yang menentukan informasi baru yang akan disimpan dalam memori, serta *output gate* (Gerbang Keluaran) yang mengontrol informasi mana yang akan digunakan sebagai output dari unit tersebut (Jason Brownlee, 2021).

3. Metode Penelitian

Seperti yang diilustrasikan pada gambar. 1, penelitian ini menggunakan model deep learning yaitu metode LSTM untuk mendeteksi prakejang epilepsi menggunakan rekaman sinyal EEG. Terdiri dari empat tahapan langkah yaitu : (1). Praproses, mengolah dataset EEG dari CHB-MIT dengan memotong sinyal berdurasi 27 detik untuk memperoleh data yang lebih terstruktur; (2). Ekstraksi fitur, menggunakan DWT untuk menangkap pola frekuensi dalam sinyal EEG, dilanjutkan dengan perhitungan fitur seperti maksimum, minimum, standar deviasi, dan mean yang disimpan dalam CSV Feature Dataset.; (3). Klasifikasi menggunakan model *deep learning* dengan metode LSTM ; (4). Evaluasi Model, mengukur kinerja model dengan metrik akurasi, presisi, recall, dan F1-score untuk menilai efektivitas klasifikasi.



Gambar 1 Proposed Model

3.1 Praproses

3.1.1 Data Sinyal EEG

Penelitian ini menggunakan data sinyal EEG dari dataset publik CHB-MIT EEG yang berasal dari Children's Hospital, Boston. Sinyal EEG direkam dari 23 anak dengan epilepsi, Data demografis tersedia untuk 22 subjek, dengan 5 subjek laki-laki berusia 3 hingga 22 tahun, dan 17 subjek perempuan berusia 1,5 hingga 19 tahun. Posisi dan nama elektroda EEG mengikuti sistem 10-20 internasional. Semua sinyal EEG diambil dengan sampling rate 256 sampel per detik dan resolusi 16-bit. Sebagian besar file sinyal mengandung 23 channel sinyal EEG. Untuk proses eksperimen, dipilih data dari 24 pasien yang menggunakan 5 channel yang sama, yang mencakup sinyal EEG saat tidak terjadi kejang dan saat terjadi kejang epilepsi. Panjang sinyal yang diambil adalah 27 detik untuk seluruh sinyal.

3.1.2. Pemotongan Sinyal EEG

Proses pemotongan sinyal dilakukan dengan membagi sinyal EEG menjadi 4 bagian ini, hal ini dilakukan untuk menganalisis dan mempelajari karakteristik masing-masing tahapan kejang pada pasien epilepsi secara terpisah untuk mendapatkan pemahaman yang lebih baik tentang penyakit tersebut. Tahapan yang dilakukan adalah sebagai berikut :

1. Tahap pertama melibatkan pemotongan sinyal EEG untuk mendapatkan bagian prakejang 1. Bagian ini mencakup periode sebelum terjadinya prakejang pertama pada pasien epilepsi.
2. Tahap selanjutnya adalah pemotongan sinyal EEG untuk mendapatkan bagian prakejang 2. Bagian ini mencakup periode antara prakejang pertama dan prakejang kedua pada pasien epilepsi.
3. Pada tahap ketiga, dilakukan pemotongan sinyal EEG untuk mendapatkan bagian prakejang 3. Bagian ini mencakup periode antara prakejang kedua dan prakejang ketiga pada pasien epilepsi.
4. Terakhir, sinyal EEG dipotong untuk mendapatkan bagian kejang. Bagian ini mencakup periode saat terjadinya kejang pada pasien epilepsi.

3.2 Ekstraksi Fitur

Langkah kedua; ekstraksi fitur menggunakan metode DWT. Proses ekstraksi fitur dilakukan guna menghilangkan redundansi pada sinyal EEG dan untuk menghasilkan fitur input dimana sinyal dibagi menjadi empat *dekomposisi* level. Diimplementasikan menggunakan low pass filter dan high pass filter dengan persamaan (1) :

$$DWT(a, b) = \frac{1}{\sqrt{|2^a|}} \int_{-\infty}^{\infty} \left(z(t) \varphi \left(\frac{t-2^a b}{2^a} \right) \right) dt \quad DWT(a, b) = \frac{1}{\sqrt{|2^a|}} \int_{-\infty}^{\infty} \left(z(t) \varphi \left(\frac{t-2^a b}{2^a} \right) \right) dt \quad (1)$$

3.3 Klasifikasi

Langkah ketiga ; Dalam deep learning, pemilihan algoritma optimasi (optimizer) sangat penting untuk mempercepat konvergensi dan meningkatkan performa model dalam meminimalkan loss function. Tiga optimizer yang sering digunakan dalam pelatihan jaringan saraf tiruan (neural network) adalah *Adaptive Moment Estimation* (Adam), *Root Mean Square Propagation* (RMSprop), dan *Stochastic Gradient Descent* (SGD). Pada penelitian ini, fitur hasil ekstraksi digunakan untuk melatih model klasifikasi, di mana proses klasifikasi dilakukan menggunakan model *deep learning* LSTM yang mencakup pra-pemrosesan data, pembangunan arsitektur LSTM, pelatihan model, dan evaluasi performa. Data yang telah dikumpulkan dipersiapkan terlebih dahulu, kemudian dibagi menjadi fitur dan label numerik sebelum dimasukkan ke dalam model. Selanjutnya, arsitektur LSTM dibangun menggunakan lapisan LSTM dan Dense, di mana proses pelatihan dilakukan untuk mengoptimalkan model dengan menggunakan optimizer Adam dengan persamaan (2), RMSprop dengan persamaan (3), dan SGD dengan persamaan (4) guna mencapai hasil klasifikasi yang optimal sebaagik berikut:

$$\theta_t = \theta_{t-1} + \alpha \left(\frac{m_t}{\sqrt{v_t + \epsilon}} \right) \quad (2)$$

$$\theta_t = \theta_{t-1} - \alpha \left(\frac{g_t}{\sqrt{E[g^2]_t + \epsilon}} \right) \quad (3)$$

$$\theta_t = \theta_{t-1} + \alpha \nabla J(\theta_{t-1}) \quad (4)$$

3.4 Evaluasi

Dalam proses ini, akan dilakukan analisis dan evaluasi hasil penelitian yang telah dilakukan. Tujuannya adalah untuk dapat menarik kesimpulan yang dapat dipertimbangkan untuk penelitian serupa di masa depan. Evaluasi akan dilakukan dengan menggunakan *confusion matrix*, di mana *precision*, *recall*, *f-1 score* dan *accuracy* akan dihitung. Proses pengujian akan dilakukan dengan mengevaluasi deteksi multikelas kejang epilepsi, seperti pada Persamaan 5 sampai dengan Persamaan 8.

$$Precision = \frac{TP}{(TP+FP)} \quad (5)$$

$$Recall = \frac{TP}{(TP+FN)} \quad (6)$$

$$F1 \text{ Score} = \frac{(2 \times Precision \times Recall)}{(Precision+Recall)} \quad (7)$$

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (8)$$

True positive (TP) terjadi ketika model berhasil mendeteksi prakejang 1-3 pada pasien yang benar-benar mengalami prakejang. *False positive* (FP) terjadi saat model salah mengklasifikasikan pasien tanpa prakejang sebagai mengalami prakejang, yang dapat menyebabkan false alarm dan intervensi yang tidak perlu. *False negative* (FN) terjadi ketika model gagal mengenali pasien dalam fase prakejang, berisiko menyebabkan keterlambatan penanganan. *True negative* (TN) adalah kondisi di mana model dengan benar mengidentifikasi pasien yang tidak berada dalam fase prakejang. Keempat metrik ini sangat penting dalam mengevaluasi akurasi model deteksi untuk prediksi prakejang epilepsi.


4. Hasil dan Pembahasan

Pada penelitian ini, data sinyal yang digunakan menggunakan data publik dari rumah sakit epilepsi CHBMIT Hospital Boston. Data sinyal yang digunakan adalah 75 sinyal yang terdiri dari 25 sinyal prakejang 1, 25 sinyal prakejang 2 dan 25 sinyal prakejang 3, tiga kelas data tersebut didapatkan dari praaproses sebelumnya yaitu pemotongan sinyal menjadi 4 bagian. Akan tetapi pada penelitian ini hanya menggunakan hasil pemotongan tiga kelas prakejang.

Tahapan selanjutnya adalah melakukan ekstraksi sinyal EEG menggunakan metode DWT. DWT digunakan untuk menganalisis sinyal EEG dengan cara mendekomposisi sinyal asli menjadi beberapa tingkat skala frekuensi yang lebih rendah. Dalam penelitian ini, sinyal EEG dibagi menjadi empat level dekomposisi, yang memungkinkan analisis lebih mendalam terhadap berbagai komponen frekuensinya, Dekomposisi ini bertujuan untuk menyaring informasi relevan dari sinyal EEG, mengurangi noise, serta mempertajam fitur yang berguna dalam tahap klasifikasi.

Pada Gambar 2, terlihat bahwa gambar sinyal yang paling atas merupakan sinyal EEG asli selanjutnya melalui proses dekomposisi menggunakan DWT dibagi menjadi empat level. Masing-masing level dekomposisi memiliki resolusi temporal dan spektral yang berbeda, dengan karakteristik sebagai berikut:

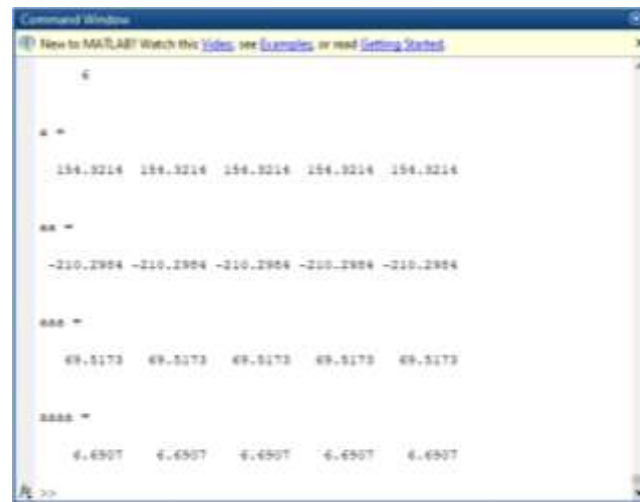
1. Dekomposisi 1: Menunjukkan sinyal dengan komponen frekuensi tertinggi, yang masih mempertahankan banyak informasi detail dari sinyal asli.
2. Dekomposisi 2: Mengandung komponen frekuensi yang lebih rendah dibandingkan level pertama, sehingga lebih halus dan kurang bising.
3. Dekomposisi 3: Representasi sinyal dengan komponen frekuensi yang lebih rendah lagi, membantu dalam mengidentifikasi pola utama yang mungkin relevan dengan deteksi kejang.
4. Dekomposisi 4: Menampilkan sinyal dengan frekuensi terendah, yang lebih stabil dan dapat digunakan untuk mendeteksi pola gelombang jangka panjang.



Gambar 2 Sample Sinyal epilepsi dibagi menjadi 4 dekomposisi

Proses selanjutnya adalah pengambilan ciri fitur dari sinyal EEG yang bertujuan untuk mengekstrak informasi penting yang dapat digunakan dalam tahap analisis dan klasifikasi, dengan fitur utama yang diambil meliputi nilai maksimum, minimum, standar deviasi, dan rata-rata (mean). Pada Gambar 3, hasil ekstraksi fitur sinyal EEG menggunakan MATLAB ditampilkan dalam *Command Window*, di mana variabel *a* mewakili nilai maksimum yang mencerminkan puncak tertinggi dari aktivitas listrik otak dan berguna untuk mengidentifikasi lonjakan atau

aktivitas abnormal, variabel aa mewakili nilai minimum yang menunjukkan titik terendah dari aktivitas listrik otak dan sering dikombinasikan dengan nilai maksimum untuk memahami rentang fluktuasi sinyal, variabel aaa mewakili *standar deviasi* yang mengukur variasi atau *dispersi* sinyal EEG, dengan standar deviasi tinggi yang mengindikasikan adanya fluktuasi besar yang bisa terkait dengan kejang atau gangguan *neurologis*, dan variabel aaaa mewakili nilai rata-rata (*mean*) yang memberikan gambaran umum tentang kecenderungan pusat data dalam periode analisis tertentu.



Gambar 3 Sample hasil pengambilan nilai ciri sinyal EEG

Tabel 1 menunjukkan variasi fluktuasi sinyal EEG, dengan beberapa sampel mengalami perubahan signifikan, seperti pada baris ke-7 yang memiliki nilai maksimum 4,5756311, minimum -0,2878686, dan standar deviasi tertinggi 0,173020691, mencerminkan lonjakan aktivitas otak. Sebaliknya, sampel pada baris ke-3 lebih stabil dengan nilai maksimum 0,3414639, minimum 0,0019578, dan standar deviasi 0,008695155. Anomali juga terlihat pada baris ke-6 dengan nilai minimum -3,653904 dan standar deviasi 0,091234446. Variasi ini mencerminkan kompleksitas pola sinyal EEG yang penting dalam klasifikasi untuk mendeteksi prakejang epilepsi, sehingga analisis ekstraksi fitur menjadi langkah krusial dalam pengembangan sistem kecerdasan buatan untuk deteksi dini kejang epilepsi.

Tabel 1. Sampel Hasil Ekstraksi Fitur

No	Max	Min	Standart Deviasi	Mean
1	0,0084534	-1,7759271	0,048696257	-0,0036727
2	0,0095367	-0,7940736	0,021676043	0,0044262
3	0,3414639	0,0019578	0,008695155	0,0042442
4	0,7576447	-0,0076003	0,023640396	0,0003849
5	0,0108681	-0,7511048	0,018732095	0,0051039
6	0,0085549	-3,653904	0,091234446	9,333E-05
7	4,5756311	-0,2878686	0,173020691	-0,0208096
8	0,0202666	-1,5037193	0,06172226	-0,0064378
9	0,0555993	-2,1308827	0,058152609	0,0054973
10	1,4514838	-0,0226437	0,037226178	0,0033773
11	3,0697176	-0,0076573	0,076265268	-0,0028439

Setelah proses pengambilan ciri fitur dari sinyal EEG yang bertujuan untuk mengekstrak informasi penting dalam tahap analisis dan klasifikasi, langkah selanjutnya adalah melakukan klasifikasi menggunakan metode LSTM. Pada penelitian ini, data sinyal yang digunakan terdiri

dari 300 sinyal EEG prakejang, yang terbagi menjadi 100 sinyal prakejang 1, 100 sinyal prakejang 2, dan 100 sinyal prakejang 3. Proses klasifikasi dilakukan dengan menerapkan tiga variasi pembagian dataset serta penggunaan variasi parameter yang berbeda pada setiap metode yang digunakan. Variasi pertama membagi dataset menjadi 90% data pelatihan (training) dan 10% data pengujian (testing), variasi kedua menggunakan 80% training dan 20% testing, sedangkan variasi ketiga menerapkan 70% training dan 30% testing. Dengan variasi pembagian ini, model LSTM diharapkan dapat mengevaluasi performa klasifikasi secara lebih optimal dan memperoleh hasil yang lebih akurat dalam mendeteksi serta memprediksi kondisi prakejang epilepsi. Berikut hasil pengujian ditunjukkan pada tabel 2, tabel 3 dan tabel 4.

Tabel 2. Uji coba menggunakan Optimizer Adam

<i>Uji Coba</i>	<i>Data Set</i>	<i>Training Set</i>	<i>Testing Set</i>	<i>Parameter (Optimizer)</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	300 Sinyal	90%	10%	Adam	95.65%	96.14%	95.65%	95.61%
2	300 Sinyal	80%	20%	Adam	98.33%	98.36%	98.33%	98.33%
3	300 Sinyal	70%	30%	Adam	98.44%	98.48%	98.44%	98.45%

Tabel 2 menyajikan hasil uji coba klasifikasi model menunjukkan bahwa optimizer Adam memiliki performa yang konsisten dan akurat dalam klasifikasi sinyal EEG, dengan akurasi tertinggi 98.44% pada skenario 70% training - 30% testing. Pada skenario 90:10, model mencapai akurasi 95.65%, sementara pada 80:20, akurasi meningkat menjadi 98.33%, menunjukkan kemampuannya beradaptasi dengan data uji yang lebih besar tanpa kehilangan performa. Hasil ini membuktikan bahwa Adam dapat menjaga kestabilan model dan meningkatkan akurasi meskipun jumlah data pelatihan berkurang.

Tabel 3. Uji coba menggunakan Optimizer RMSprop

<i>Uji Coba</i>	<i>Data Set</i>	<i>Training Set</i>	<i>Testing Set</i>	<i>Parameter (Optimizer)</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	300 Sinyal	90%	10%	RMSprop	95.65%	96.14%	95.65%	95.61%
2	300 Sinyal	80%	20%	RMSprop	98.33%	98.42%	98.33%	98.33%
3	300 Sinyal	70%	30%	RMSprop	98.44%	98.46%	98.44%	98.44%

Tabel 3 menyajikan hasil uji coba klasifikasi model menunjukkan bahwa optimizer RMSprop memiliki performa yang stabil dan akurat dalam klasifikasi sinyal EEG, dengan akurasi tertinggi 98.44% pada skenario 70% training -30% testing. Pada skenario 90:10, model mencapai akurasi 95.65%, sementara pada 80:20, akurasi meningkat menjadi 98.33%, menunjukkan kemampuan model mengenali pola meskipun jumlah data pelatihan berkurang. Dengan *Precision* dan *Recall* yang tinggi di setiap skenario, hasil ini membuktikan bahwa RMSprop mampu menjaga kestabilan, menghindari overfitting, dan tetap akurat dalam mendeteksi pola EEG.

Tabel 4. Uji coba menggunakan Optimizer SGD

<i>Uji Coba</i>	<i>Data Set</i>	<i>Training Set</i>	<i>Testing Set</i>	<i>Parameter (Optimizer)</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	300 Sinyal	90%	10%	SGD	95.65%	96.14%	95.65%	95.64%
2	300 Sinyal	80%	20%	SGD	98.00%	98.03%	98%	97.99%
3	300 Sinyal	70%	30%	SGD	98.22%	98.23%	98.22%	98.22%

Tabel 4 menyajikan hasil uji coba klasifikasi model menunjukkan bahwa optimizer SGD memiliki performa yang stabil dan akurat dalam klasifikasi sinyal EEG, dengan akurasi tertinggi 98.22% pada skenario 70% training - 30% testing. Pada skenario 90:10, model mencapai akurasi 95.65%, sedangkan pada 80:20, akurasi meningkat menjadi 98.00%, menunjukkan kemampuannya dalam mendeteksi pola dengan presisi tinggi meskipun jumlah data uji bertambah. Dengan Precision dan Recall yang tinggi di setiap skenario, hasil ini membuktikan bahwa SGD dapat menjaga keseimbangan antara akurasi, presisi, dan recall, menjadikannya optimizer yang efektif dalam klasifikasi sinyal EEG.

5. Kesimpulan

Penelitian ini membahas deteksi prakejang pada pasien epilepsi berdasarkan rekaman sinyal EEG menggunakan metode LSTM, dengan tahapan prapemrosesan, ekstraksi fitur menggunakan DWT, dan klasifikasi menggunakan model LSTM. Model dikembangkan dengan tiga skenario pembagian data training dan testing (90:10, 80:20, 70:30) serta dioptimalkan menggunakan Adam, RMSprop, dan SGD untuk meningkatkan performa deteksi. Hasil uji coba menunjukkan bahwa semua optimizer memberikan akurasi tinggi, dengan RMSprop sebagai yang terbaik, mencapai 98.44% pada skenario 70% training - 30% testing, serta menunjukkan kestabilan dalam *Precision* (98.46%), *Recall* (98.44%), dan *F1-Score* (98.44%), yang mengindikasikan kemampuannya dalam mengurangi overfitting dan mempertahankan akurasi model. Secara keseluruhan, penelitian ini membuktikan bahwa metode LSTM dengan optimasi yang tepat dapat meningkatkan akurasi deteksi prakejang epilepsi, menjadikannya alat yang efektif dalam diagnosis dini dan manajemen epilepsi berbasis kecerdasan buatan (AI). Hasil penelitian ini dapat menjadi dasar bagi pengembangan sistem deteksi kejang otomatis yang lebih akurat dan real-time, berkontribusi dalam aplikasi medis berbasis AI untuk meningkatkan kualitas hidup pasien epilepsi.

Referensi

- Akut, R. (2019). Wavelet based deep learning approach for epilepsy detection. *Health Information Science and Systems*, 7(1), 1–9. <https://doi.org/10.1007/s13755-019-0069-1>
- Djougack Nkengfack, L. C., Tchiotop, D., Atangana, R., Louis-Door, V., & Wolf, D. (2021). Classification of EEG signals for epileptic seizures detection and eye states identification using Jacobi polynomial transforms-based measures of complexity and least-square support vector machine. *Informatics in Medicine Unlocked*, 23. <https://doi.org/10.1016/j.imu.2021.100536>
- Dwaraka, H., Subhas, P. C., & Naidu, K. R. (2020). Automatic epileptic seizure recognition using reliefF feature selection and long short term memory classifier. *Journal of Ambient Intelligence and Humanized Computing*, 0123456789. <https://doi.org/10.1007/s12652-020-02185-7>
- Harpale, V., & Bairagi, V. (2018). An adaptive method for feature selection and extraction for classification of epileptic EEG signal in significant states. *Journal of King Saud University - Computer and Information Sciences*. <https://doi.org/10.1016/j.jksuci.2018.04.014>
- Hussein, R., Palangi, H., Ward, R. K., & Wang, Z. J. (2019). Optimized deep neural network architecture for robust detection of epileptic seizures using EEG signals. *Clinical Neurophysiology*, 130(1), 25–37. <https://doi.org/10.1016/j.clinph.2018.10.010>
- Jamaaluddin, J., Anshory, I., Tedjo, S., Hindarto, Fudholi, A., Ahmudiarto, Y., Martides, E., & Sopian, K. (2024). Heat Transfer Management of Solar Power Plant for Dryer. *International Journal on Engineering Applications*, 12(3), 195–203. <https://doi.org/10.15866/irea.v12i3.23959>
- Jamaluddin, Akbar, A., & Khoiri. (2023). Design Water Flow Measurement with Ultra Sonic Sensor. *Engineering and Applied Technology*, 1(2), 123–130.
- Jason Brownlee. (2021). *How to Develop Voting Ensembles With Python*. 2017. <https://machinelearningmastery.com/voting-ensembles-with-python/>
- Metzinger, J. L. (2016). Signs and symptoms. *Uveitic Glaucoma*, 87–92.

- <https://doi.org/10.4324/9780429201738-1>
- Mohanty, S. N., Chatterjee, J. M., Mangla, M., Satpathy, S., & Potluri, S. (Eds.). (2021). *Machine Learning Approach for Cloud Data Analytics in Io*. This edition first published 2021 by John Wiley & Sons, Inc., 111 River Street, Hoboken, NJ 07030, USA and Scrivener Publishing LLC, 100 Cummings Center, Suite 541J, Beverly, MA 01915, USA.
- Page, A., Sagedy, C., Smith, E., Attaran, N., Oates, T., & Mohsenin, T. (2015). A flexible multichannel EEG feature extractor and classifier for seizure detection. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 62(2), 109–113. <https://doi.org/10.1109/TCSII.2014.2385211>
- Qureshi, M. B., Afzaal, M., Qureshi, M. S., & Fayaz, M. (2021). *Machine learning-based EEG signals classification model for epileptic seizure detection*. 17849–17877.
- Saminu, S., Xu, G., Shuai, Z., Abd, I., Kader, E., Jabire, A. H., Ahmed, Y. K., Karaye, I. A., & Ahmad, I. S. (2021). *brain sciences A Recent Investigation on Detection and Classification of Epileptic Seizure Techniques Using EEG Signal*.
- Sharmila, A. (2018). Epilepsy detection from EEG signals: a review. *Journal of Medical Engineering and Technology*, 42(5), 368–380. <https://doi.org/10.1080/03091902.2018.1513576>
- Tzimourta, K. D., Tzallas, A. T., Giannakeas, N., Astrakas, L. G., Tsalikakis, D. G., Angelidis, P., & Tsiouras, M. G. (2018). *A robust methodology for classification of epileptic seizures in EEG signals*.
- WHO. (2019). *Epilepsy*. 19 Juni. <https://www.who.int/news-room/fact-sheets/detail/epilepsy>
- Zhou, D., & Li, X. (2020). Epilepsy EEG Signal Classification Algorithm Based on Improved RBF. *Frontiers in Neuroscience*, 14(June), 1–7. <https://doi.org/10.3389/fnins.2020.00606>