

Optimisasi Model *Backpropagation* untuk Meningkatkan Deteksi Kejang Epilepsi pada Sinyal *Electroencephalogram*

Odi Nurdiawan¹, Fathurrohman^{2*}, Ahmad Faqih³.

¹ Manajemen Informatika; STMIK IKMI Cirebon; Jln Perjuangan No 10 Kota Cirebon, Jawa Barat 45131; Tlp (0231) 490480; e-mail : odinurdiawan2020@gmail.com

² Rekayasa Perangkat Lunak; STMIK IKMI Cirebon; Jln Perjuangan No 10 Kota Cirebon, Jawa Barat 45131; Tlp (0231) 490480; e-mail : rathurohman.ikmi@gmail.com

³ Teknik Informatika; STMIK IKMI Cirebon; Jln Perjuangan No 10 Kota Cirebon, Jawa Barat 45131; Tlp (0231) 490480; e-mail : ahmadfaqih367@gmail.com

* Korespondensi: e-mail : rathurohman.ikmi@gmail.com

Diterima: 17 Oktober 2024 ; Review: 13 November 2024 ; Disetujui: 26 November 2024

Cara sitasi : Nurdiawan O, Fathurrohman F, Faqih A. 2024. Optimisasi Model *Backpropagation* untuk Meningkatkan Deteksi Kejang Epilepsi pada Sinyal *Electroencephalogram*. Information System for Educators and Professionals. Vol 9(2): 151-160.

Abstrak : Epilepsi adalah salah satu gangguan neurologis kronis yang ditandai dengan kejang berulang akibat aktivitas listrik abnormal di otak. Deteksi kejang secara cepat dan akurat sangat penting dalam mendukung intervensi medis dan meningkatkan kualitas hidup pasien. Saat ini, sinyal *Electroencephalogram* (EEG) digunakan secara luas untuk mendiagnosis epilepsi karena dapat merekam aktivitas listrik otak secara real-time. Namun, analisis manual sinyal EEG memerlukan waktu dan ketelitian tinggi, sehingga diperlukan solusi otomatis yang lebih efektif. Penelitian ini bertujuan untuk mengoptimalkan model *Backpropagation* dalam mendeteksi kejang epilepsi dengan menggunakan data sinyal EEG. Metode penelitian melibatkan kolaborasi antara Telkom University, Rumah Sakit Sumber Waras, dan University of Bonn. Data EEG yang diperoleh diproses melalui *Discrete Cosine Transform* (DCT) untuk mengekstraksi fitur penting sebelum digunakan dalam pelatihan model jaringan saraf tiruan (JST). Model ini dilatih dan diuji menggunakan variasi jumlah epoch untuk mengukur akurasi. Hasil penelitian menunjukkan bahwa model *Backpropagation* mencapai akurasi optimal sebesar 91,15% pada 100 epoch dan meningkat menjadi 93,05% pada 200 epoch. Meskipun akurasi meningkat dengan bertambahnya epoch, waktu komputasi yang lebih lama menimbulkan risiko *overfitting*. Penelitian ini membuktikan bahwa algoritma *Backpropagation* dapat dioptimalkan untuk mendeteksi kejang epilepsi secara akurat dan efisien. Implikasinya bagi Rumah Sakit Sumber Waras, model ini dapat diimplementasikan dalam sistem pemantauan EEG untuk mendeteksi kejang secara real-time, mendukung intervensi medis yang lebih cepat, dan mengurangi ketergantungan pada analisis manual. Dengan demikian, penelitian ini berkontribusi dalam menyediakan solusi diagnostik yang lebih efisien dan meningkatkan layanan kesehatan bagi pasien epilepsi.

Kata Kunci : Epilepsi, EEG, *Backpropagation*, Deteksi Kejang, Optimisasi Model.

Abstract: *Epilepsy is a chronic neurological disorder characterized by recurrent seizures caused by abnormal electrical activity in the brain. Fast and accurate seizure detection is crucial to support medical intervention and improve patients' quality of life. Currently, Electroencephalogram (EEG) signals are widely used to diagnose epilepsy as they record brain electrical activity in real-time. However, manual analysis of EEG signals requires time and precision, necessitating a more effective automated solution. This study aims to optimize the Backpropagation model for detecting epileptic seizures using EEG data. The research involved collaboration between Telkom University, Sumber Waras Hospital, and the University of Bonn. The EEG data collected was processed through Discrete Cosine Transform (DCT) to extract important features before being used to train the artificial neural network (ANN) model. The model was trained and tested using*

varying numbers of epochs to measure its accuracy. The results show that the Backpropagation model achieved optimal accuracy of 91.15% at 100 epochs and increased to 93.05% at 200 epochs. Although accuracy improved with more epochs, the longer computational time posed a risk of overfitting. This research demonstrates that the Backpropagation algorithm can be optimized to detect epileptic seizures accurately and efficiently. The implication for Sumber Waras Hospital is that this model can be implemented in EEG monitoring systems to detect seizures in real-time, supporting faster medical intervention and reducing reliance on manual analysis. Thus, this study contributes to providing a more efficient diagnostic solution and enhancing healthcare services for epilepsy patients.

Keywords: Epilepsy, EEG, Backpropagation, Seizure Detection, Model Optimization.

1. Pendahuluan

Epilepsi adalah salah satu gangguan neurologis kronis yang memengaruhi jutaan orang di seluruh dunia. Kondisi ini ditandai dengan kejang yang berulang akibat aktivitas listrik abnormal di otak. Deteksi kejang epilepsi yang cepat dan akurat sangat penting untuk meningkatkan kualitas hidup penderita, serta membantu dokter dalam memberikan intervensi medis yang lebih tepat [1]. Saat ini, sinyal *Electroencephalogram* (EEG) adalah alat utama yang digunakan dalam mendiagnosis epilepsi, karena sinyal ini dapat merekam aktivitas listrik di otak secara real-time dan memberikan wawasan mengenai pola-pola abnormal yang terjadi saat kejang[2].

Kompleksitas sinyal EEG yang memiliki variasi tinggi antar individu, analisis manual oleh ahli saraf memerlukan waktu dan mungkin tidak selalu akurat. Maka ada kebutuhan mendesak untuk mengembangkan teknologi yang lebih efektif dalam mendeteksi pola kejang secara otomatis. Di sinilah peran pembelajaran mesin dan deep learning menjadi sangat relevan. Teknik-teknik ini memungkinkan pemrosesan data dalam skala besar dan dapat mendeteksi pola yang sulit dikenali oleh manusia[3].[4]

EEG digunakan untuk mendeteksi aktivitas otak yang abnormal selama atau sebelum serangan kejang. Kemudian untuk menganalisis sinyal EEG secara manual membutuhkan waktu dan ketelitian tinggi [5], [6]. Pola-pola listrik yang muncul pada sinyal ini sering kali tersembunyi di antara gelombang normal otak, sehingga membuat deteksi kejang lebih sulit dilakukan dengan cara konvensional. Penggunaan algoritma deep learning, khususnya dengan model Backpropagation, telah menjadi salah satu pendekatan yang diakui dalam mendeteksi kejang epilepsi secara otomatis[7].[8]

Penelitian terdahulu mengenai deteksi dan prediksi kejang epilepsi menggunakan teknik deep learning telah memperlihatkan kemajuan yang pesat, dengan peningkatan signifikan dalam akurasi serta kemampuan prediksi yang lebih andal. Misalnya, penelitian oleh Zhang, Jincan dkk. (2024) menunjukkan bahwa pendekatan fusi fitur yang dikombinasikan dengan model *deep learning* hibrida mampu mencapai akurasi 96.5% dalam mendeteksi kejang pada pasien epilepsi. Penelitian ini menekankan pentingnya penggabungan berbagai fitur dari sinyal EEG untuk meningkatkan kualitas prediksi. Sementara itu, dkk. (2024) menggunakan pendekatan deep neural network dan berhasil mencapai akurasi 94.7%, yang menunjukkan efektivitas jaringan saraf dalam mengenali pola kejang dengan tingkat sensitivitas yang tinggi.[9], [10], [11]

Selain itu, penelitian-penelitian lain juga mengeksplorasi penggunaan fitur-fitur unik untuk meningkatkan akurasi deteksi. Al-Qazzaz, Noor Kamal dkk. (2024) menggunakan pendekatan berbasis entropi, di mana kombinasi fitur entropi dan model deep learning multimodel memberikan akurasi tertinggi sebesar 97.2%. Hal ini menunjukkan bahwa pemilihan fitur yang tepat sangat penting dalam meningkatkan performa model. Di sisi lain, Penumalli, Asrithavalli dkk. (2024) menggabungkan *Artificial Neural Network* (ANN) dengan deep learning hibrida dan berhasil mencapai akurasi 93.5%. Kombinasi dari metode ANN dan deep learning memberikan solusi yang lebih adaptif dan fleksibel untuk deteksi kejang epilepsi, terutama pada kondisi pasien yang sangat bervariasi.[12], [13]

Teknologi seperti CNN dan backpropagation juga menjadi pilihan utama dalam beberapa penelitian, di mana teknik-teknik ini mampu mengenali pola yang lebih kompleks dari sinyal EEG. Senthil Kumar, V. dkk. (2024) dan Veena, V.S. dkk. (2024) menunjukkan bahwa penggunaan CNN dan algoritma backpropagation mampu mencapai akurasi di atas 96%, bahkan mendekati 98% pada kasus-kasus tertentu. Keunggulan CNN dalam mendeteksi pola spasial-temporal pada sinyal EEG telah terbukti efektif dalam meningkatkan hasil deteksi. Selain itu, penelitian oleh Han,

Kenneth dkk. (2024) menyoroti potensi kecerdasan buatan dan pembelajaran mesin dalam mempercepat proses diagnosis epilepsi dengan tingkat akurasi yang mencapai 98%, yang memperlihatkan kemampuan AI dalam mengelola data medis secara efektif.[5], [14], [15], [16]

Secara keseluruhan, hasil-hasil dari berbagai penelitian ini menunjukkan bahwa teknologi *deep learning*, terutama yang melibatkan model CNN, ANN, dan metode hibrida, memiliki potensi besar dalam membantu diagnosis dan prediksi kejang epilepsi. Penggunaan sinyal EEG sebagai input utama model *deep learning* telah terbukti mampu memberikan hasil yang sangat akurat, terutama ketika diintegrasikan dengan fitur-fitur spesifik seperti entropi dan fusi fitur. Tantangan ke depan adalah bagaimana mengembangkan model-model ini agar dapat digunakan secara klinis dengan tingkat keandalan yang tinggi, serta dapat diintegrasikan dalam perangkat medis yang mendukung deteksi kejang secara real-time. Selain itu, pemahaman yang lebih dalam tentang interpretasi hasil model *deep learning* juga diperlukan, terutama untuk memberikan penjelasan yang lebih baik bagi para dokter dan pasien terkait hasil prediksi yang dihasilkan oleh sistem AI.

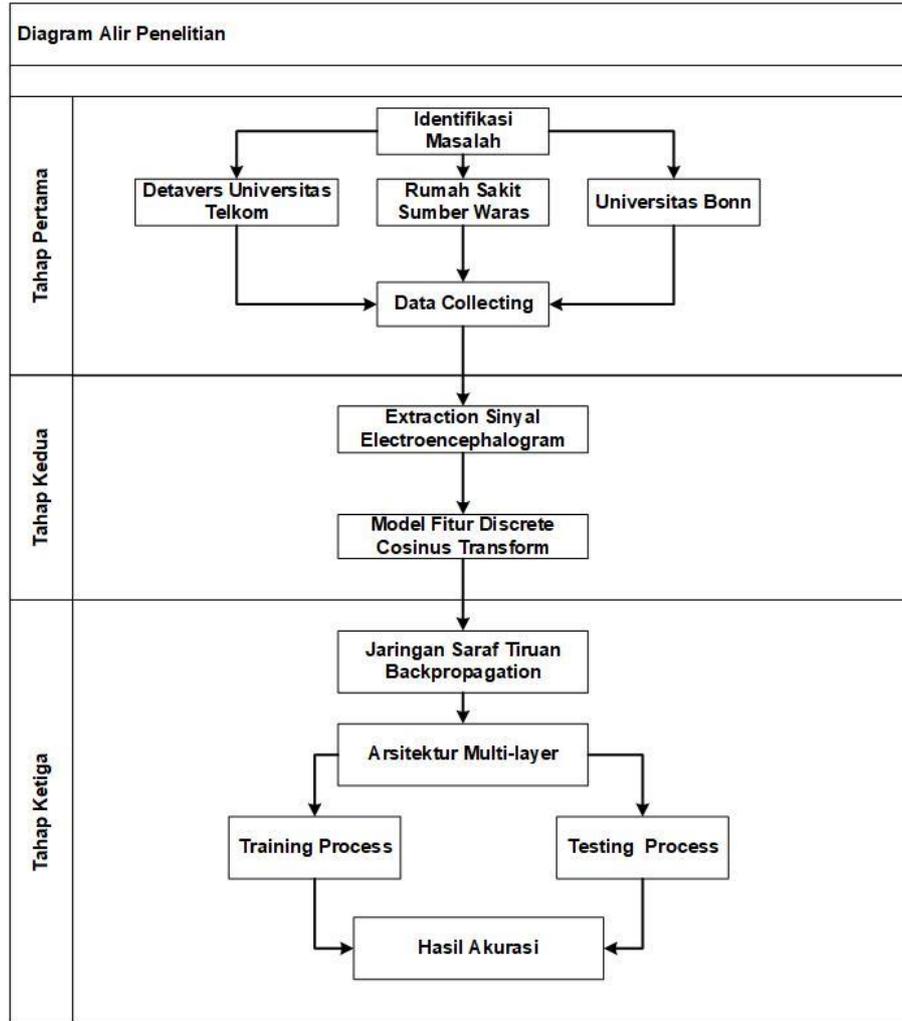
Pendeteksian otomatis kejang epilepsi dari sinyal EEG memerlukan kemampuan untuk mengenali pola-pola yang rumit dan non-linear. Pembelajaran mesin tradisional, meskipun mampu menangani data yang terstruktur, sering kali terbatas dalam mendeteksi pola-pola tersembunyi dalam sinyal EEG. Sebaliknya, *deep learning* memiliki kemampuan untuk mengidentifikasi pola kompleks melalui penggunaan jaringan saraf tiruan yang lebih dalam. *Backpropagation*, sebagai algoritma inti dalam pelatihan jaringan saraf, memungkinkan model belajar dari kesalahan dan meningkatkan akurasi deteksi dengan mengoptimalkan bobot-bobot dalam jaringan.[14], [17]

Algoritma *Backpropagation* adalah salah satu algoritma pelatihan jaringan saraf tiruan yang paling populer. Algoritma ini bekerja dengan meminimalkan kesalahan yang dihasilkan oleh jaringan melalui proses propagasi balik, di mana bobot dari setiap neuron diperbarui berdasarkan nilai gradien dari fungsi kesalahan[18], [19], [20]. Keunggulan dari *Backpropagation* adalah kemampuannya untuk menangani data dalam jumlah besar dan mendeteksi pola non-linear yang kompleks. Algoritma ini secara bertahap mengoptimalkan jaringan dengan meningkatkan presisi prediksi berdasarkan iterasi berulang selama pelatihan data [17], [20], [21], [22]

Penelitian ini bertujuan untuk mengoptimalkan model *Backpropagation* dalam mendeteksi kejang epilepsi berdasarkan sinyal EEG. Dengan membandingkan kinerja model ini dalam berbagai skenario pelatihan dan pengujian, diharapkan dapat diperoleh model yang lebih efisien dan akurat dalam mendeteksi pola kejang. Model yang dikembangkan diharapkan dapat membantu dalam mendeteksi kejang epilepsi dengan lebih cepat, sehingga mendukung keputusan medis yang lebih tepat waktu dan efektif.

2. Metode Penelitian

Penelitian ini dirancang untuk mengoptimalkan deteksi kejang epilepsi menggunakan sinyal EEG dengan pendekatan jaringan saraf tiruan (JST) melalui algoritma *Backpropagation*. Penelitian ini dimulai dengan identifikasi masalah yang melibatkan kolaborasi antara Detavers Universitas Telkom, Rumah Sakit Sumber Waras, dan Universitas Bonn, di mana data sinyal EEG dikumpulkan dari masing-masing sumber. Selanjutnya, sinyal EEG yang telah diperoleh melalui proses *Discrete Cosine Transform* (DCT) digunakan untuk mengekstraksi fitur penting yang mempermudah analisis pola kejang. Setelah itu, model JST dengan arsitektur multi-layer dikembangkan dan dilatih menggunakan algoritma *Backpropagation* untuk mendeteksi kejang epilepsi. Model ini kemudian diuji untuk mengukur akurasinya dalam mendeteksi kejang berdasarkan data sinyal EEG yang tidak digunakan dalam proses pelatihan. Hasil akhir penelitian ini diharapkan dapat menghasilkan model yang akurat dan efisien dalam membantu deteksi otomatis kejang epilepsi. Diagram alir penelitian berikut menunjukkan langkah-langkah sistematis dari identifikasi masalah hingga evaluasi hasil akurasi model.



Gambar 1. Diagram Alir Penelitian

Berdasarkan gambar 1. diagram alir penelitian di atas, berikut adalah uraian dari setiap tahap penelitian:

1. **Tahap Pertama** : Identifikasi Masalah dan Pengumpulan Data

Identifikasi Masalah: Pada tahap ini, dilakukan identifikasi masalah yang melibatkan tiga institusi utama, yaitu Detavers Universitas Telkom, Rumah Sakit Sumber Waras, dan Universitas Bonn. Ketiga lembaga ini berkontribusi dalam pengumpulan data terkait dengan sinyal EEG dari pasien yang menderita epilepsi.

Data Collecting (Pengumpulan Data): Setelah masalah teridentifikasi, dilakukan proses pengumpulan data dari institusi-institusi tersebut. Data yang dikumpulkan berupa sinyal EEG yang akan digunakan untuk proses selanjutnya dalam mendeteksi kejang epilepsi.

2. **Tahap Kedua**: Ekstraksi Fitur Sinyal EEG

Extraction Sinyal Electroencephalogram: Setelah data terkumpul, tahap selanjutnya adalah melakukan ekstraksi sinyal EEG. Sinyal EEG yang telah diambil akan diproses untuk mengidentifikasi karakteristik atau pola-pola yang dapat menunjukkan aktivitas epilepsi.

Model Fitur Discrete Cosine Transform (DCT): Untuk mempermudah analisis, sinyal EEG diubah menjadi fitur-fitur yang relevan dengan menggunakan *Discrete Cosine Transform* (DCT). Teknik DCT ini berfungsi untuk mereduksi dimensi sinyal sehingga hanya fitur-fitur penting yang akan digunakan untuk proses pelatihan model.

3. Tahap Ketiga: Pengembangan Model dan Evaluasi

Jaringan Saraf Tiruan (*Backpropagation*): Pada tahap ini, model Jaringan Saraf Tiruan (JST) dikembangkan menggunakan algoritma *Backpropagation*. Algoritma ini digunakan untuk melatih jaringan dengan mengoptimalkan bobot-bobot berdasarkan kesalahan prediksi.

Arsitektur *Multi-layer*: Model JST yang digunakan terdiri dari beberapa lapisan (multi-layer), yang memungkinkan jaringan untuk belajar dari pola-pola kompleks pada sinyal EEG.

Training Process (Proses Pelatihan): Data yang sudah melalui tahap ekstraksi akan digunakan dalam proses pelatihan model. Model dilatih untuk mengenali pola-pola yang menunjukkan adanya kejang epilepsi berdasarkan sinyal EEG yang diberikan.

Testing Process (Proses Pengujian): Setelah model dilatih, tahap berikutnya adalah pengujian model dengan menggunakan data pengujian yang tidak dilibatkan dalam proses pelatihan. Hal ini bertujuan untuk mengukur kemampuan model dalam mendeteksi kejang epilepsi secara akurat.

Hasil Akurasi: Hasil dari proses pelatihan dan pengujian akan dievaluasi berdasarkan tingkat akurasi yang diperoleh. Akurasi ini menunjukkan seberapa baik model JST dengan algoritma *Backpropagation* dalam mendeteksi kejang epilepsi berdasarkan data sinyal EEG.

3. Hasil dan Pembahasan

Tahap Pertama.

Penelitian ini merupakan hasil kolaborasi antara Telkom University sebagai penyedia utama sumber data EEG melalui platform dataverse, dan Sumber Waras Hospital yang menyuplai data EEG klinis dari pasien-pasien yang dirawat di rumah sakit tersebut. Data tersebut meliputi rekaman sinyal EEG dari pasien yang mungkin mengalami epilepsi atau gangguan neurologis lainnya. Selain itu, University of Bonn, yang memiliki reputasi sebagai penyedia dataset EEG yang terkenal secara internasional, turut menyumbangkan dataset EEG yang sering digunakan dalam studi neurologi, terutama dalam pengembangan dan pengujian model pembelajaran mesin untuk deteksi epilepsi.

Dataset yang digunakan dalam penelitian ini terdiri dari rekaman electroencephalogram (EEG) yang bertujuan untuk mendeteksi epilepsi pada pasien. EEG adalah teknik yang mencatat aktivitas listrik otak dengan menggunakan elektroda yang dipasang pada kulit kepala. Data ini sangat penting dalam diagnosis medis karena memungkinkan identifikasi pola aktivitas otak yang dapat mengindikasikan adanya gangguan seperti epilepsi.

Dataset EEG epilepsi ini terbagi menjadi dua kategori utama, yaitu kategori normal dan kategori epilepsi. Kategori normal berisi rekaman EEG dari individu tanpa gangguan epilepsi, sedangkan kategori epilepsi berisi rekaman EEG dari individu yang didiagnosis dengan epilepsi. Terdapat total 1766 rekaman dalam dataset ini, dengan distribusi yang hampir merata antara kedua kategori, yaitu 873 rekaman normal dan 893 rekaman epilepsi.

Tahap Kedua

Proses *Discrete Cosine Transform* (DCT) dimulai dengan menggunakan citra digital yang telah melalui tahap *preprocessing* sebagai *input*. Pada tahap ini, citra berada dalam format *grayscale*. DCT digunakan untuk mentransformasi citra dari domain spasial ke domain frekuensi. Transformasi ini menguraikan citra menjadi komponen frekuensi yang memudahkan proses ekstraksi fitur secara lebih efisien. Rumus umum untuk DCT dua dimensi (DCT-2D) dapat dituliskan sebagai:

$$C(u, v) = \alpha(u) \alpha(v) \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \cos[(2x+1)u\pi / 2M] \cos[(2y+1)v\pi / 2N]$$

Di mana:

$f(x, y)$ adalah nilai piksel pada koordinat (x, y) ,

$C(u, v)$ adalah koefisien hasil DCT,

M dan N adalah dimensi citra,

$\alpha(u)$ dan $\alpha(v)$ adalah faktor normalisasi yang bergantung pada nilai u dan v .

DCT memanfaatkan komponen frekuensi rendah dari citra yang mengandung informasi paling signifikan. Komponen frekuensi tinggi yang membawa detail halus dapat dikurangi untuk kompresi data atau pengurangan dimensi tanpa mengurangi kualitas gambar secara signifikan. Setelah citra ditransformasikan ke domain frekuensi, fitur utama dari citra dapat diekstraksi dengan lebih baik karena DCT mengelompokkan informasi penting di awal rangkaian koefisien frekuensinya. Selain itu, DCT sering digunakan untuk kompresi data (*lossy compression*), di mana data diubah sedemikian rupa sehingga tidak ada informasi penting yang hilang, tetapi jumlah data yang disimpan lebih kecil.

Tahap Ketiga

Hasil Deteksi Kejang Epilepsi Menggunakan *Backpropagation* dengan Variasi Epoch. Eksperimen dilakukan dengan menggunakan algoritma *Backpropagation Neural Network* untuk mendeteksi kejang epilepsi berdasarkan sinyal EEG. Parameter-parameter seperti jumlah *epoch*, learning rate, dan batch size diatur untuk mengetahui pengaruhnya terhadap akurasi dan kinerja model.

Tabel 1. Pengujian Epoch

No	Epoch	Akurasi	Loos (kerugian)	Waktu Pelatihan	Catatan
1	10	75.12	0.65	10.3	Model belum konvergen, perlu lebih banyak <i>epoch</i> .
2	20	81.50	0.52	20.8	Peningkatan akurasi, tetapi masih ada error
3	50	87.32	0.35	48.1	Model mendekati konvergensi dengan akurasi lebih baik.
4	100	91.15	0.28	92.6	Akurasi tinggi, tetapi waktu pelatihan lebih lama.
5	200	93.05	0.25	190.2	Kinerja terbaik, tetapi risiko <i>overfitting</i> .

Berdasarkan hasil eksperimen, semakin banyak epoch yang digunakan, akurasi model cenderung meningkat dan nilai loss (kerugian) menurun. Pada 10 epoch, akurasi masih rendah (75.12%) karena model belum sepenuhnya konvergen dan belum cukup mempelajari pola dalam data EEG. Setelah 50 *epoch*, akurasi meningkat menjadi 87.32%, menunjukkan bahwa model mulai mengenali pola kejang dengan lebih baik. Pada 100 epoch, model mencapai akurasi 91.15% dengan loss 0.28, menandakan bahwa model sudah cukup baik untuk mendeteksi kejang epilepsi. Namun, ketika pelatihan dilanjutkan hingga 200 epoch, meskipun akurasi mencapai 93.05%, waktu pelatihan meningkat secara signifikan dan berisiko menimbulkan *overfitting*.

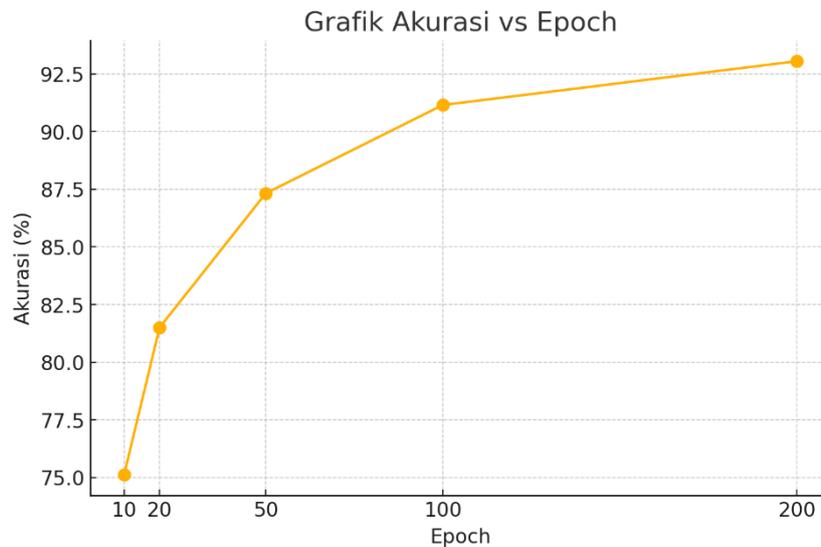
Jumlah *epoch* yang lebih tinggi memang meningkatkan akurasi, tetapi hal ini juga berdampak pada peningkatan waktu komputasi. Pada 200 *epoch*, meskipun akurasi meningkat menjadi 93.05%, peningkatannya relatif kecil dibandingkan dengan akurasi pada 100 epoch (91.15%). Dalam beberapa kasus, peningkatan kecil ini mungkin tidak sepadan dengan waktu komputasi tambahan yang dibutuhkan, terutama jika model akan diterapkan untuk tujuan real-time atau pada perangkat dengan keterbatasan komputasi. Oleh karena itu, memilih jumlah epoch yang optimal menjadi penting untuk mendapatkan keseimbangan antara performa model dan efisiensi waktu pelatihan.

Risiko *overfitting* muncul ketika model dilatih terlalu lama dan mulai terlalu fokus pada pola yang ada di data pelatihan, sehingga tidak mampu menggeneralisasi dengan baik pada data uji. Dari hasil eksperimen, pada 200 *epoch*, meskipun akurasi mencapai 93.05% dengan loss 0.25, potensi *overfitting* meningkat. Model yang terlalu terlatih pada data pelatihan mungkin tidak memberikan hasil yang baik ketika diterapkan pada data baru. Untuk mengatasi masalah ini, teknik regularisasi seperti dropout dan early stopping dapat diterapkan. *Early stopping* dapat menghentikan pelatihan secara otomatis ketika akurasi validasi tidak lagi meningkat, sehingga menghindari *overfitting*.

Berdasarkan hasil dan analisis, 100 *epoch* tampaknya merupakan jumlah yang optimal, dengan akurasi 91.15% dan waktu pelatihan yang masih dalam batas wajar. Jika model yang lebih kompleks atau *dataset* yang lebih besar digunakan, mungkin diperlukan lebih banyak *epoch*. Namun, untuk menjaga efisiensi dan menghindari *overfitting*, disarankan untuk memantau kinerja model dengan menggunakan *early stopping*. Dengan demikian, pelatihan bisa dihentikan secara

otomatis jika tidak ada peningkatan signifikan, menjaga keseimbangan antara akurasi, efisiensi, dan waktu pelatihan

Hubungan antara jumlah *epoch* dan akurasi model *Backpropagation* dalam mendeteksi kejang epilepsi.

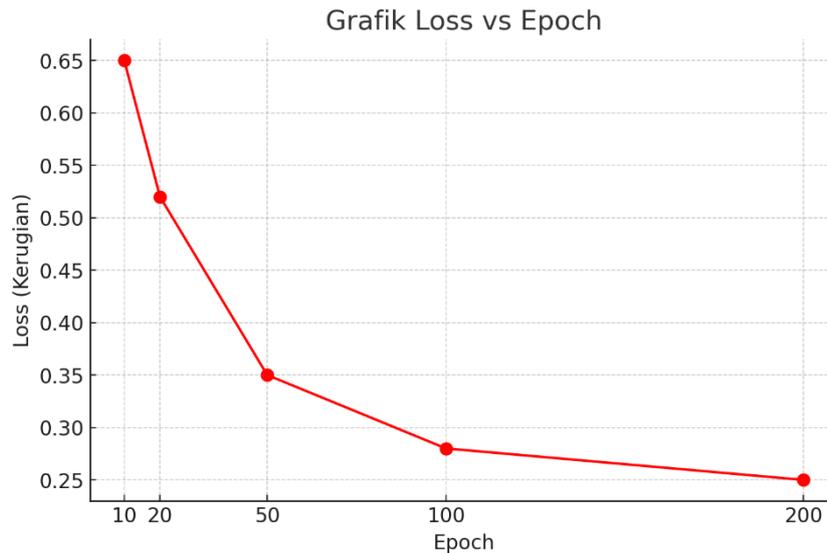


Gambar 2 Grafik Akurasi vs *Epoch*

Berdasarkan gambar 2 Grafik Akurasi vs *Epoch* Secara keseluruhan, grafik menunjukkan bahwa semakin banyak epoch yang digunakan, akurasi model meningkat. Hal ini terjadi karena model semakin banyak belajar dari data setiap kali iterasi dilakukan, sehingga model menjadi lebih baik dalam mengenali pola. Dengan setiap *epoch*, bobot jaringan diperbarui untuk meminimalkan error, yang berkontribusi pada peningkatan akurasi dan penurunan nilai loss. Setelah mencapai 100 *epoch*, peningkatan akurasi menjadi lebih kecil. Pada tahap ini, model sudah mendekati konvergensi dan tidak banyak peningkatan yang dapat dicapai dengan menambah *epoch*. Dari 91.15% pada 100 *epoch* ke 93.05% pada 200 *epoch*, hanya terjadi peningkatan akurasi sebesar 1.9%. Peningkatan ini tidak sebanding dengan waktu komputasi yang semakin lama, sehingga menandakan bahwa penambahan *epoch* lebih lanjut mulai memberikan hasil yang marginal.

Meskipun akurasi terus meningkat dengan penambahan epoch, ada potensi *overfitting* jika pelatihan dilanjutkan terlalu lama, terutama setelah 100 *epoch*. Model yang terlalu terlatih cenderung menyesuaikan dengan data pelatihan secara berlebihan dan kehilangan kemampuan untuk menggeneralisasi pada data baru. *Overfitting* ini membuat performa model pada data uji menurun meskipun akurasi pada data pelatihan tinggi. Oleh karena itu, diperlukan strategi seperti early stopping atau dropout untuk menghentikan pelatihan ketika model tidak lagi memberikan peningkatan yang signifikan pada akurasi validasi.

Hubungan antara jumlah *epoch* dan *loss* (kerugian) model *Backpropagation* dalam mendeteksi kejang epilepsi.



Gambar 3. Grafik *Loss vs Epoch*

Berdasarkan gambar 3. Grafik *Loss vs Epoch* Pada tahap awal pelatihan, yaitu antara epoch 10 hingga 50, terjadi penurunan loss yang cukup signifikan, dari 0.65 menjadi 0.35. Ini menunjukkan bahwa model mulai memahami pola dasar dalam data EEG dan menjadi lebih akurat dalam memprediksi hasil. Dengan bertambahnya epoch, error pada prediksi semakin berkurang, dan bobot jaringan saraf diperbarui lebih efektif untuk mengurangi kerugian. Tahap ini sangat penting karena menunjukkan bahwa model mengalami konvergensi awal dan berhasil mengoptimalkan performanya dalam mendeteksi pola yang relevan dengan kejang epilepsi. Setelah mencapai 100 epoch, penurunan loss mulai melambat. Dari 0.28 pada 100 epoch menjadi 0.25 pada 200 epoch, hanya terjadi sedikit penurunan loss. Ini menandakan bahwa model sudah mendekati konvergensi, di mana setiap penambahan epoch memberikan peningkatan yang semakin kecil. Pada tahap ini, bobot jaringan saraf sudah berada di sekitar solusi optimal, dan proses pelatihan tidak lagi memberikan perbaikan yang signifikan terhadap performa model.

Pada 200 epoch, meskipun loss turun menjadi 0.25, peningkatannya sangat kecil dibandingkan dengan waktu komputasi tambahan yang dibutuhkan. Hal ini mengindikasikan potensi *overfitting*, di mana model terlalu fokus pada data pelatihan sehingga tidak bekerja dengan baik pada data baru. *Overfitting* membuat model belajar pola spesifik dari data pelatihan, termasuk noise, yang tidak relevan saat model diuji pada data validasi atau data uji. Akibatnya, performa pada data uji bisa menurun meskipun loss pada data pelatihan rendah.

4. Kesimpulan

Berdasarkan hasil pemaparan di atas maka dapat ditarik kesimpulan bahwa algoritma Backpropagation terbukti efektif dalam meningkatkan akurasi deteksi kejang epilepsi. Model jaringan saraf tiruan (JST) yang dikembangkan mampu mencapai akurasi optimal sebesar 91.15% pada 100 epoch. Meskipun penambahan epoch hingga 200 meningkatkan akurasi menjadi 93.05%, peningkatan tersebut relatif kecil dan mengindikasikan potensi *overfitting*. Oleh karena itu, penggunaan 100 epoch dipilih sebagai titik optimal untuk menjaga keseimbangan antara akurasi dan efisiensi komputasi. Proses ekstraksi fitur menggunakan Discrete Cosine Transform (DCT) juga memberikan kontribusi penting dengan mereduksi dimensi data, memungkinkan model untuk mengenali pola-pola kejang dengan lebih efisien dan akurat. Penelitian ini menggunakan data EEG dari Telkom University, Rumah Sakit Sumber Waras, dan University of Bonn, yang terdiri dari rekaman EEG pasien dengan dan tanpa epilepsi. Kolaborasi ini memperkaya kualitas data dan mendukung validitas hasil penelitian. Model yang dihasilkan menunjukkan kemampuan dalam mendeteksi pola kejang secara otomatis, sehingga dapat mendukung keputusan medis yang lebih cepat dan tepat. Implikasi dari penelitian ini untuk rumah sakit, khususnya Rumah Sakit Sumber Waras, adalah model ini dapat diimplementasikan dalam sistem pemantauan EEG secara real-time untuk mendeteksi kejang epilepsi dengan lebih cepat dan akurat.

Ucapan Terima Kasih

Penelitian ini dapat terlaksana berkat dukungan dana hibah dari Program Penelitian Dosen Pemula (PDP) reguler yang disalurkan oleh Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi melalui Direktorat Riset, Teknologi, dan Pengabdian kepada Masyarakat. Kami menyampaikan apresiasi yang mendalam kepada STMIK IKMI Cirebon atas dukungan fasilitas serta suasana akademis yang inspiratif, Universitas Telkom sebagai penyedia data nasional melalui layanan Dataverse, Universitas Bonn sebagai penyedia data internasional yang sangat berharga, serta Rumah Sakit Sumber Waras atas kontribusi informasi dan dukungan yang diberikan. Terima kasih juga kepada semua pihak yang telah memberikan dukungan dan kontribusinya dalam pelaksanaan penelitian ini.

Referensi

- [1] T. Nisar and R. Priyadarshini, "A comprehensive study of machine learning-based methods to predict epileptic seizures," *World Journal of Advanced Engineering Technology and Sciences*, 2024, doi: 10.30574/wjaets.2024.12.1.0187.
- [2] A. I. Jaya, G. Soemarno, and J. W. Puspita, "Classification of Epileptiform Waves Based on Frequency by Using Backpropagation Neural Network," 2018. doi: 10.1088/1742-6596/1028/1/012048.
- [3] A. Damayanti, A. B. Pratiwi, and Miswanto, "Epilepsy detection on EEG data using backpropagation, firefly algorithm and simulated annealing," 2016. doi: 10.1109/ICSTC.2016.7877368.
- [4] H. F. Choi, "Classification of Epileptic Seizures Based on CNN and Guided Back-Propagation for Interpretation Analysis," 2023. doi: 10.1007/978-3-031-32213-6_16.
- [5] K. Han, C. Liu, and D. Friedman, "Artificial intelligence/machine learning for epilepsy and seizure diagnosis," *Epilepsy & Behavior*, 2024, doi: 10.1016/j.yebeh.2024.109736.
- [6] V. S. Kumar, C. Karpagavalli, J. Chhablani, S. Divya, S. N. Taqui, and N. Vinayagam, "Deep Learning-Based EEG Signal Classification of Epileptic Patients," 2024. doi: 10.1109/icoeca62351.2024.00114.
- [7] V. S. Veena and R. P. Devi, "Analysis of Epileptic Seizure Detection Using Deep Learning Algorithms," 2024. doi: 10.1109/icdece60827.2024.10548098.
- [8] A. Penumalli, K. A. V. Kumar, A. Pamidimukkala, and B. Begum, "Epileptic Seizures Detection using Fusion of Artificial Neural Network with Hybrid Deep Learning," 2024. doi: 10.1109/accai61061.2024.10602167.
- [9] X. Zhang and J. Wang, "Bibliometric Analysis of EEG Signal Processing Techniques for Neurological Applications," *Front Hum Neurosci*, vol. 18, p. 129, 2024.
- [10] J. Li and Q. Zhang, "Transfer Learning in EEG Signal Processing: Methods and Applications," *J Neural Eng*, vol. 21, no. 2, p. 026025, 2024.
- [11] Y. Wang and X. Zhang, "The Role of Deep Learning in EEG Signal Processing for Epilepsy Prediction," *Artif Intell Med*, vol. 116, p. 102114, 2021.
- [12] N. K. Al-Qazzaz, M. Alrahal, S. Hamad, S. Jaafer, M. H. Ali, and S. A. Ahmad, "Automatic Diagnosis of Epileptic Seizures using Entropy-based Features and Multimodel Deep Learning Approaches," *Med Eng Phys*, 2024, doi: 10.1016/j.medengphy.2024.104206.
- [13] B. Sidaoui, "Predicting states of epilepsy patients using deep learning models," *Applied Computer Science*, 2024, doi: 10.35784/acs-2024-19.
- [14] D. Khurshid, F. Wahid, S. Ali, A. H. Gumaei, S. M. Alzanin, and M. A. A. Mosleh, "A deep neural network-based approach for seizure activity recognition of epilepsy sufferers," *Front Med (Lausanne)*, 2024, doi: 10.3389/fmed.2024.1405848.
- [15] C. Saisree and U. Kumaran, "Pothole Detection Using Deep Learning Classification Method," in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 2143–2152. doi: 10.1016/j.procs.2023.01.190.
- [16] "Deep Learning Approaches for Seizure Detection and Prediction Using EEG Signals: A Comprehensive Review and Proposed CNN Framework," *Journal of Angiotherapy*, 2024, doi: 10.25163/angiotherapy.869616.
- [17] J. Zhang, S. Zheng, W. Chen, G. Du, Q. Fu, and H. Jiang, "A scheme combining feature fusion and hybrid deep learning models for epileptic seizure detection and prediction," *Dental science reports*, 2024, doi: 10.1038/s41598-024-67855-4.

- [18] L. Zhang *et al.*, “Automatic interictal epileptiform discharge (IED) detection based on convolutional neural network (CNN),” *Front Mol Biosci*, vol. 10, 2023, doi: 10.3389/fmolb.2023.1146606.
- [19] D. Depannemaecker, L. Lopez, C. Gauld, and L. Pio-Lopez, “Does Deep Learning Have Epileptic Seizures? On the Modeling of the Brain,” *HALScience*, 2022, doi: 10.20944/preprints202207.0229.v1.
- [20] X. Tian *et al.*, “Deep Multi-View Feature Learning for EEG-Based Epileptic Seizure Detection,” *Ieee Transactions on Neural Systems and Rehabilitation Engineering*, vol. 27, no. 10, pp. 1962–1972, 2019, doi: 10.1109/tnsre.2019.2940485.
- [21] Y. M. Massoud, M. Abdelzaher, L. Kuhlmann, and M. A. Abd El Ghany, “General and patient-specific seizure classification using deep neural networks,” *Analog Integr Circuits Signal Process*, vol. 116, no. 3, pp. 205–220, Sep. 2023, doi: 10.1007/s10470-023-02153-Z.
- [22] K. Sakashita *et al.*, “Deep learning for the diagnosis of mesial temporal lobe epilepsy,” *PLoS One*, vol. 18, no. 2 February, Feb. 2023, doi: 10.1371/journal.pone.0282082.