

Deteksi Kelainan Jantung Berdasarkan Sinyal Elektrokardiogram (EKG) Menggunakan Deep Neural Network

Michael Robert*, Yennimar, Andy Wyjaya, Steven Ebert, Mhd. Ali Ramadhan

Fakultas Sains dan Teknologi, Program Studi Teknik Informatika, Universitas Prima Indonesia, Medan, Indonesia

Email: ¹Michaelrobert0803@gmail.com, ²yennimar@unprimdn.ac.id, ³andywijayatba2011@gmail.com,

⁴stevenebert77@gmail.com, ⁵amuhammad0728@gmail.com

Email Penulis Korespondensi: Michaelrobert0803@gmail.com*

Submitted: 25/05/2025; Accepted: 23/06/2025; Published: 30/06/2025

Abstrak—Penyakit jantung merupakan salah satu penyebab utama kematian di dunia, termasuk di Indonesia. Deteksi dini kelainan jantung melalui sinyal elektrokardiogram (EKG) sangat penting, namun interpretasi manual oleh tenaga medis sering kali memerlukan keahlian khusus dan rentan terhadap kesalahan. Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis kelainan jantung menggunakan metode *Deep Neural Network* (DNN) berdasarkan sinyal EKG. Dataset yang digunakan berasal dari *PTB Diagnostic ECG Database* (PTBDB) yang diperoleh dari Kaggle, dengan dua kategori data: normal dan abnormal. Data diproses melalui tahap *balancing*, normalisasi, dan pembagian menjadi data latih dan uji. Model DNN dilatih menggunakan data terstruktur berdurasi pendek dengan 187 fitur, dan dievaluasi menggunakan metrik akurasi, *precision*, *recall*, *f1-score*, ROC, serta *Precision-Recall Curve*. Hasil pelatihan menunjukkan bahwa model mampu mencapai akurasi validasi sebesar 95% dan nilai AUC sebesar 0,98, yang mengindikasikan kemampuan klasifikasi yang sangat baik. Dengan performa tersebut, model ini memiliki potensi besar untuk diterapkan dalam sistem pendukung diagnosis medis secara real-time, terutama untuk membantu deteksi dini gangguan jantung secara efisien dan akurat.

Kata Kunci: Deep Neural Network; Sinyal EKG; Deteksi Kelainan Jantung; Klasifikasi; Deep Learning.

Abstract— Cardiovascular disease is one of the leading causes of death worldwide, including in Indonesia. Early detection of heart abnormalities through electrocardiogram (ECG) signals is crucial; however, manual interpretation by medical professionals often requires specialized expertise and is prone to error. This study aims to develop an automatic heart abnormality detection system using a *Deep Neural Network* (DNN) based on ECG signals. The dataset used was obtained from the *PTB Diagnostic ECG Database* (PTBDB) via Kaggle, consisting of two categories: normal and abnormal. The data underwent preprocessing steps including balancing, normalization, and splitting into training and testing sets. The DNN model was trained using short-duration structured data with 187 features, and evaluated using metrics such as accuracy, precision, recall, F1-score, ROC curve, and Precision-Recall curve. The training results show that the model achieved a validation accuracy of 95% and an AUC score of 0.98, indicating excellent classification performance. With this level of performance, the model holds significant potential for real-time deployment in medical diagnostic support systems, particularly for the efficient and accurate early detection of heart disorders.

Keywords: Deep Neural Network; ECG Signal; Heart Abnormality Detection; Classification; Deep Learning.

1. PENDAHULUAN

Penyakit jantung menjadi salah satu penyebab utama kematian baik di Indonesia maupun di seluruh dunia, dengan angka kejadian yang terus mengalami peningkatan setiap tahunnya [1] [2]. Hal ini menimbulkan beban berat bagi sistem pelayanan kesehatan nasional, sebagaimana data dari Kementerian Kesehatan Republik Indonesia yang menunjukkan tingginya angka kematian akibat penyakit jantung, biaya perawatan yang besar, serta rendahnya tingkat deteksi dini [3] [4] [5]. Masalah ini semakin diperparah oleh keterbatasan akses masyarakat terhadap tenaga medis dan teknologi diagnostik, terutama di daerah-daerah terpencil yang minim fasilitas kesehatan [6] [7]. Deteksi dini kelainan jantung sangat penting untuk mencegah komplikasi serius dan kematian, dan salah satu metode yang efektif adalah melalui analisis sinyal elektrokardiogram (EKG) [8] [9] [10]. Namun, interpretasi sinyal EKG secara manual memerlukan keahlian khusus dan cenderung subjektif, sehingga berpotensi menimbulkan kesalahan diagnosis yang dapat berdampak fatal [11][12]. Selain itu, keterbatasan tenaga ahli dan fasilitas diagnostik di daerah terpencil memperparah rendahnya tingkat deteksi dini penyakit jantung [13] [14].


Berbagai penelitian sebelumnya telah mengkaji teknologi deteksi kelainan jantung dengan pendekatan yang beragam. Misalnya [15] dalam penelitiannya melibatkan koreksi sinyal EKG dari gangguan, ekstraksi 13 fitur utama, dan pengembangan klasifikasi berdasarkan karakteristik ini. Dibandingkan dengan Jaringan Syaraf Tiruan (NN), Support Vector Machine (SVM), dan K-Nearest Neighbor (KNN) pada database aritmia MIT-BIH, klasifikasi yang diusulkan menunjukkan kinerja superior dengan akurasi rata-rata mencapai 99%, menunjukkan potensi besar untuk implementasi klinis. [16] mengeksplorasi berbagai pendekatan modern berbasis pembelajaran mesin untuk klasifikasi penyakit jantung dari rekaman EKG menggunakan representasi Poincaré dengan *deep learning* gambar, model konvolusional satu dimensi (1D), dan model XGBoost dengan fitur deret waktu dan memberikan hasil kinerja terbaik dengan skor F1 masing-masing 85% dan 71%. [17] meningkatkan klasifikasi otomatis penyakit kardiovaskular (PKV) menggunakan sinyal EKG dengan mengusulkan pendekatan *Deep Learning* (DL) hibrida yang mengintegrasikan Convolutional Neural Network (CNN) dan Variational Autoencoder (VAE) dengan akurasi 98,51%, spesifisitas 98,12%, sensitivitas 97,9%, dan skor F1 97,95%, serta

tingkat *false positive* dan *false negative* yang minimal. [18] mengusulkan pendekatan baru untuk mendeteksi Penyakit Kardiovaskular (PKV) melalui analisis gambar EKG menggunakan pemrosesan gambar yang ditingkatkan dan teknik *deep learning*, khususnya Convolutional Neural Network (CNN) dan membandingkan model *deep learning*, EfficientNetV2 dan MobileNet, menunjukkan kinerja superior dari EfficientNetV2 dengan akurasi 99,72% dan rasio kesalahan 0,28%, sedikit mengungguli MobileNet (akurasi 99,69%, rasio kesalahan 0,30%). Meskipun presisi keduanya sama (87,5%), MobileNet memberikan evaluasi yang lebih komprehensif dengan *recall* (93,33%) dan F1-score (90,32%). [19] menggunakan berbagai algoritma *machine learning*, *deep learning*, dan *ensemble learning* seperti SVM, CNN, dan XGBoost dalam deteksi dini dan klasifikasi akurat penyakit jantung (HD) melalui analisis sinyal EKG. Analisis menunjukkan bahwa CNN secara konsisten mencapai akurasi luar biasa (rata-rata 98,83%), sementara model LSTM unggul dalam sensitivitas pada dataset PTB-XL (rata-rata *recall* 88,01%). SVM dan KNN juga menunjukkan akurasi kompetitif (96,20% dan 97,50%) [20]. mengembangkan algoritma efisien berbasis korelasi silang dua langkah untuk deteksi *real-time* kelainan sinyal EKG dan identifikasi penyakit jantung. algoritma ini menunjukkan akurasi deteksi 100% untuk tujuh penyakit yang disimulasikan. Langkah korelasi kedua berhasil membedakan penyakit dengan nilai koefisien korelasi yang dekat, mempercepat proses hingga 40%. Meskipun telah banyak penelitian yang mendeteksi kelainan jantung secara otomatis melalui analisis sinyal EKG, hasil yang diperoleh masih menghadapi beberapa kendala. Salah satu tantangan utama adalah kurangnya representasi data lokal dalam pengembangan model, sehingga akurasi deteksi pada populasi Indonesia belum optimal. Selain itu, implementasi sistem yang efisien dan dapat diakses secara luas, khususnya di daerah terpencil dengan keterbatasan fasilitas kesehatan, masih menjadi hambatan tersendiri. Model-model yang ada umumnya belum diuji secara menyeluruh pada kondisi nyata di lapangan, sehingga efektivitasnya dalam mendukung layanan kesehatan digital masih perlu ditingkatkan. Berdasarkan permasalahan tersebut, penelitian ini berupaya menghadirkan solusi yang lebih adaptif terhadap karakteristik data lokal dan dapat diimplementasikan secara praktis, sehingga diharapkan mampu meningkatkan akurasi, kecepatan, dan jangkauan deteksi kelainan jantung di Indonesia.

Berdasarkan permasalahan dan kajian literatur tersebut, penelitian ini memiliki tujuan utama untuk mengembangkan model Deep Neural Network yang efektif dalam mendeteksi kelainan jantung dari sinyal EKG dengan akurasi yang lebih tinggi dibandingkan metode konvensional. Selain itu, penelitian ini bertujuan mengotomatisasi proses analisis sinyal EKG agar menjadi lebih cepat dan efisien, serta melakukan evaluasi performa model menggunakan dataset standar yang representative. Diharapkan solusi teknologi yang dikembangkan dapat diimplementasikan dalam sistem kesehatan digital yang mendukung transformasi layanan kesehatan di Indonesia. Dengan demikian, penelitian ini diharapkan dapat membantu tenaga medis dalam melakukan diagnosis yang lebih akurat, menurunkan risiko kesalahan interpretasi manual, serta meningkatkan akses deteksi dini penyakit jantung, khususnya di wilayah dengan keterbatasan fasilitas medis. Secara keseluruhan, penelitian ini tidak hanya berkontribusi pada kemajuan teknologi kecerdasan buatan di bidang kesehatan, tetapi juga memberikan dampak positif yang signifikan bagi peningkatan kualitas pelayanan kesehatan nasional.

2. METODOLOGI PENELITIAN

Kerangka kerja penelitian merupakan sebuah gambaran penelitian yang dibuat untuk mempermudah proses berlangsungnya penelitian. Adapun kerangka kerja penelitian yang digunakan dalam penelitian ini adalah :



Gambar 1. Kerangka Kerja Penelitian

1. Preprocessing Data

Tahap preprocessing data merupakan langkah penting yang bertujuan untuk mempersiapkan dataset agar siap digunakan dalam proses pelatihan model. Pada tahap ini, dilakukan beberapa langkah krusial yang memastikan kualitas dan konsistensi data, sehingga model yang dikembangkan dapat belajar dengan efektif dan menghasilkan prediksi yang akurat. Pertama, dilakukan pengecekan terhadap nilai kosong atau missing value dalam dataset untuk mengidentifikasi dan menangani data yang tidak lengkap, karena keberadaan nilai kosong

dapat mengganggu proses pelatihan dan menurunkan performa model. Selanjutnya, dilakukan normalisasi fitur sinyal EKG, yaitu proses mengubah skala data agar berada dalam rentang tertentu yang seragam, sehingga setiap fitur memiliki kontribusi yang seimbang dalam pelatihan model dan mencegah dominasi fitur tertentu yang memiliki nilai lebih besar. Terakhir, dilakukan penyeimbangan jumlah data antar kelas menggunakan teknik undersampling, yang bertujuan mengatasi ketimpangan jumlah data antara kelas normal dan abnormal. Ketidakseimbangan ini jika tidak ditangani dapat menyebabkan model bias terhadap kelas mayoritas, sehingga dengan undersampling, jumlah data pada kelas mayoritas dikurangi agar proporsinya seimbang dengan kelas minoritas, sehingga model dapat belajar secara adil dan meningkatkan kemampuan klasifikasi pada kedua kelas tersebut.

2. Pembangunan Model (Model Development)

Setelah data melalui tahap persiapan dan preprocessing yang matang, langkah selanjutnya adalah pembangunan model Deep Neural Network (DNN). Pada tahap ini, model dikembangkan dengan merancang struktur lapisan yang mampu mengenali pola-pola kompleks yang terdapat pada sinyal EKG. Struktur model DNN terdiri dari beberapa lapisan yang saling berhubungan, mulai dari lapisan input yang menerima data sinyal EKG, lapisan tersembunyi yang melakukan ekstraksi fitur dan pemrosesan nonlinier, hingga lapisan output yang menghasilkan klasifikasi akhir. Setiap lapisan dirancang dan dioptimalkan secara khusus untuk meningkatkan kemampuan model dalam membedakan antara sinyal EKG normal dan abnormal, sehingga model dapat melakukan klasifikasi biner dengan akurasi tinggi. Proses pembangunan model ini juga melibatkan pemilihan fungsi aktivasi, jumlah neuron pada setiap lapisan, serta teknik regularisasi yang bertujuan untuk mencegah overfitting dan memastikan model dapat melakukan generalisasi dengan baik pada data baru.

3. Pelatihan Model (Training)

Setelah model Deep Neural Network dibangun, tahap berikutnya adalah pelatihan model menggunakan data latih yang telah melalui proses preprocessing sebelumnya. Pada tahap ini, model belajar mengenali pola-pola dalam data dengan menyesuaikan bobot dan bias pada setiap neuron melalui proses iteratif yang berlangsung selama beberapa epoch. Selama pelatihan, performa model secara berkala dipantau menggunakan teknik early stopping, yang berfungsi untuk menghentikan proses pelatihan secara otomatis ketika model mulai menunjukkan tanda-tanda overfitting, yaitu ketika akurasi pada data latih meningkat tetapi performa pada data validasi menurun. Selain itu, model checkpoint juga diterapkan untuk menyimpan versi terbaik dari model berdasarkan metrik evaluasi tertentu, sehingga jika pelatihan terhenti atau terjadi penurunan performa, model dapat kembali ke kondisi terbaik yang pernah dicapai. Dengan menggabungkan kedua teknik ini, proses pelatihan dapat berjalan secara efisien dan efektif, memastikan model tidak hanya belajar dengan baik dari data latih, tetapi juga mampu melakukan generalisasi yang baik pada data baru, sehingga menghasilkan hasil prediksi yang optimal dan dapat diandalkan.

4. Pengujian Model (Testing)

Setelah proses pelatihan model selesai, tahap selanjutnya adalah pengujian model menggunakan data uji yang benar-benar baru dan belum pernah dilihat oleh model sebelumnya. Pengujian ini sangat penting untuk menilai kemampuan generalisasi model, yaitu sejauh mana model dapat menerapkan pengetahuan yang diperoleh selama pelatihan pada data yang berbeda dan tidak dikenal. Dengan menggunakan data uji yang terpisah, evaluasi ini memberikan gambaran objektif mengenai performa model dalam kondisi nyata, di luar lingkungan pelatihan. Hasil dari pengujian ini akan menunjukkan seberapa akurat dan andal model dalam mendeteksi kelainan jantung berdasarkan sinyal EKG pada kasus-kasus baru, sehingga dapat memastikan bahwa model tidak hanya menghafal data latih tetapi benar-benar mampu mengenali pola-pola penting yang relevan untuk klasifikasi. Tahapan pengujian ini menjadi langkah krusial dalam menentukan kelayakan model untuk diimplementasikan dalam aplikasi klinis atau sistem deteksi real-time.


5. Evaluasi dan Visualisasi Hasil

Evaluasi performa model dilakukan dengan menggunakan berbagai metrik yang saling melengkapi untuk memberikan gambaran menyeluruh mengenai kemampuan model dalam melakukan klasifikasi. Metrik pertama adalah akurasi, yang mengukur seberapa sering model menghasilkan prediksi yang benar secara keseluruhan, namun akurasi ini kurang dapat diandalkan apabila data tidak seimbang. Untuk mengatasi hal tersebut, digunakan metrik precision yang menunjukkan proporsi prediksi positif yang benar dari seluruh prediksi positif yang dibuat oleh model, sangat penting terutama dalam konteks diagnosis medis agar kesalahan prediksi positif dapat diminimalkan. Selanjutnya, recall mengukur kemampuan model dalam mendeteksi seluruh kasus positif yang sebenarnya, sehingga metrik ini berguna untuk meminimalkan kasus yang terlewatkan. F1-score kemudian digunakan sebagai rata-rata harmonik antara precision dan recall, memberikan ukuran kinerja yang seimbang terutama saat terdapat ketidakseimbangan kelas. Selain itu, confusion matrix digunakan untuk menampilkan secara rinci jumlah prediksi benar dan salah yang terbagi ke dalam empat kategori: true positive, false positive, true negative, dan false negative, sehingga memudahkan analisis kesalahan model. Untuk visualisasi performa model secara lebih komprehensif, digunakan juga kurva ROC (Receiver Operating Characteristic) yang memplot true positive rate terhadap false positive rate di berbagai threshold, serta kurva Precision-Recall yang menggambarkan trade-off antara precision dan recall.

3. HASIL DAN PEMBAHASAN


3.1 Hasil Preprocessing

Hasil pemeriksaan menunjukkan bahwa tidak terdapat *missing value* pada kedua dataset. "Distribusi Kelas PTBDB Sebelum Balancing", terlihat bahwa jumlah data pada kelas "Abnormal" jauh lebih banyak dibandingkan kelas "Normal", dengan kelas "Abnormal" memiliki lebih dari 10.000 sampel sedangkan kelas "Normal" hanya sekitar 4.000 sampel. Ketidakseimbangan ini dapat menyebabkan bias pada model pembelajaran mesin.



Gambar 2. Distribusi Kelas PTBDB Sebelum Balancing


Setelah dilakukan balancing, seperti yang ditampilkan pada grafik kedua, "Distribusi Kelas PTBDB Sesudah Balancing", jumlah sampel pada kedua kelas menjadi seimbang, masing-masing sekitar 4.000 sampel. Proses balancing ini biasanya dilakukan dengan teknik undersampling pada kelas mayoritas, sehingga distribusi data antara kelas "Normal" dan "Abnormal" menjadi setara dan model dapat belajar secara adil dari kedua kelas.



Gambar 3. Distribusi Kelas PTBDB Sesudah Balancing

Setelah digabungkan, data terdiri dari 4.048 data normal dan 10.586 data abnormal. Setelah balancing dengan undersampling, masing-masing kelas memiliki 4.048 sampel. Data kemudian dinormalisasi dan dibagi menjadi data latih dan validasi.

3.2 Hasil Pelatihan Model



Gambar 4. PTBDB Loss and Accuracy Curve


Performa model selama proses pelatihan menggunakan dataset PTBDB dapat dilihat dari bentuk kurva *loss*, di mana sumbu Y menunjukkan nilai *loss* dan sumbu X menunjukkan jumlah epoch. Terlihat bahwa nilai *loss* pada data latih (*Train Loss*) dan data validasi (*Val Loss*) sama-sama mengalami penurunan seiring bertambahnya epoch, yang menandakan bahwa model semakin baik dalam mempelajari pola data. Sedangkan kurva akurasi, dengan sumbu Y menunjukkan nilai akurasi dan sumbu X menunjukkan epoch. Akurasi pada data latih (*Train Accuracy*) dan data validasi (*Val Accuracy*) terus meningkat hingga mencapai nilai di atas 0,95, menunjukkan bahwa model memiliki performa yang sangat baik dalam mengklasifikasikan data. Model DNN berhasil dilatih dengan akurasi validasi terbaik sebesar $\pm 95\%$ pada epoch ke-34, sesuai dengan hasil *EarlyStopping*. Kurva *loss* dan akurasi tersebut menunjukkan konvergensi yang stabil dan tidak terjadi *overfitting*, sehingga model dapat dikatakan berhasil belajar dengan baik dan siap untuk digunakan pada tahap evaluasi selanjutnya.

3.3 Evaluasi Model

	precision	recall	f1-score	support
Normal	0.94	0.96	0.95	810
Abnormal	0.96	0.94	0.95	809
accuracy			0.95	1619
macro avg	0.95	0.95	0.95	1619
weighted avg	0.95	0.95	0.95	1619


Gambar 5. Hasil Evaluasi Performa Model

Hasil evaluasi performa model klasifikasi menggunakan metrik *precision*, *recall*, *f1-score*, dan *support* untuk masing-masing kelas, yaitu "Normal" dan "Abnormal". Pada kelas "Normal", model memperoleh *precision* sebesar 0,94, *recall* 0,96, dan *f1-score* 0,95 dari total 810 sampel. Artinya, model mampu mengidentifikasi data normal dengan tingkat ketepatan dan sensitivitas yang sangat baik. Sementara itu, pada kelas "Abnormal", *precision* yang dicapai adalah 0,96, *recall* 0,94, dan *f1-score* 0,95 dari 809 sampel, menunjukkan model juga sangat baik dalam mendeteksi data abnormal.




Gambar 6. Confusion Matrix PTBDB

Confusion matrix hasil evaluasi model klasifikasi pada dataset PTBDB. Terdapat dua kelas utama, yaitu "Normal" dan "Abnormal". Dari 810 data aktual "Normal", sebanyak 776 data berhasil diklasifikasikan dengan benar sebagai "Normal", sementara 34 data lainnya salah diklasifikasikan sebagai "Abnormal". Sedangkan dari 809 data aktual "Abnormal", sebanyak 759 data berhasil dikenali dengan benar sebagai "Abnormal", dan 50 data sisanya salah diklasifikasikan sebagai "Normal". *Confusion matrix* ini menunjukkan bahwa model memiliki tingkat akurasi yang tinggi dalam membedakan kedua kelas, dengan jumlah prediksi benar yang jauh lebih besar dibandingkan prediksi salah. Hal ini menandakan bahwa model DNN yang digunakan mampu melakukan klasifikasi sinyal EKG secara efektif pada kedua kelas.



Gambar 7. ROC Curve PTBDB

Kurva ROC menampilkan hubungan antara True Positive Rate (TPR) di sumbu Y dan False Positive Rate (FPR) di sumbu X untuk berbagai nilai ambang batas klasifikasi. Pada grafik ini, terdapat dua kurva yaitu untuk kelas "Abnormal" (garis biru) dan "Normal" (garis oranye), masing-masing dengan nilai AUC (*Area Under Curve*) sebesar 0,98. Nilai AUC yang mendekati 1, yaitu 0,98 untuk kedua kelas, menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antara kelas "Normal" dan "Abnormal". Semakin tinggi nilai AUC, semakin baik performa model dalam melakukan klasifikasi, karena model mampu memaksimalkan tingkat deteksi positif benar (*true positive*) dan meminimalkan kesalahan deteksi positif palsu (*false positive*). Kurva ROC yang berada jauh di atas garis diagonal (garis putus-putus) juga menandakan bahwa model tidak melakukan prediksi secara acak, melainkan benar-benar dapat membedakan kedua kelas dengan sangat baik.




Gambar 8. Precision-Recall Curve PTBDB

Kurva ini *Precision-Recall* untuk model klasifikasi pada dataset PTBDB memiliki hubungan antara nilai *precision* (ketepatan) pada sumbu Y dan *recall* (sensitivitas) pada sumbu X untuk berbagai ambang batas prediksi. Berdasarkan grafik, terlihat bahwa *precision* model tetap sangat tinggi di hampir seluruh rentang *recall*, bahkan mendekati nilai 1.0, sebelum akhirnya menurun tajam saat *recall* mendekati 1.0. Nilai *Average Precision* (AP) yang dicapai adalah 0,98, yang menunjukkan bahwa model memiliki performa yang sangat baik dalam membedakan antara kelas "Normal" dan "Abnormal". Kurva yang mendekati sudut kanan atas grafik menandakan bahwa model mampu mempertahankan *precision* yang tinggi meskipun *recall* juga tinggi. Hal ini sangat penting dalam aplikasi medis seperti deteksi sinyal EKG, karena model tidak hanya mampu mendeteksi sebagian besar kasus abnormal (*recall* tinggi), tetapi juga meminimalkan kesalahan deteksi (*precision* tinggi).

3.4 Visualisasi Deteksi

Model divisualisasikan terhadap 10 sampel acak, termasuk yang salah prediksi. Warna merah digunakan untuk prediksi salah, dan hijau untuk yang benar. Analisis ini menunjukkan bahwa sebagian besar kesalahan terjadi pada sinyal abnormal yang menyerupai normal (*false negative*), kemungkinan disebabkan oleh *noise* atau pola tidak khas.



Gambar 9. Visualisasi Deteksi 10 Sampel acak

Visualisasi deteksi 10 sampel acak sinyal EKG dari dataset PTBDB, yang menampilkan hasil prediksi model untuk masing-masing sampel. Setiap subplot memperlihatkan satu sinyal EKG dengan label "True" yang menunjukkan kelas sebenarnya (Normal atau Abnormal) dan "Pred" yang menunjukkan hasil prediksi model. Sinyal yang digambarkan dengan warna hijau menandakan prediksi model benar (sesuai dengan label aslinya), sedangkan warna merah menunjukkan prediksi yang salah. Dari visualisasi ini, dapat dilihat bahwa sebagian besar sinyal berhasil diklasifikasikan dengan tepat oleh model, baik untuk kelas "Normal" maupun "Abnormal". Namun, masih terdapat beberapa kasus di mana model melakukan kesalahan prediksi, seperti pada sampel pertama dan keempat di baris atas, serta beberapa sampel di baris bawah. Visualisasi ini sangat membantu untuk memahami bagaimana model mengenali pola sinyal EKG dan di mana model masih mengalami kesulitan dalam membedakan antara sinyal normal dan abnormal.

3.5 Pembahasan

Dataset sinyal EKG normal dan abnormal dimuat dan digabung menjadi satu, dengan label kelas yang didefinisikan agar hasil klasifikasi mudah dipahami. Untuk meningkatkan kemampuan model dalam mengenali variasi sinyal nyata, diterapkan data augmentation berupa penambahan noise, pergeseran waktu, perubahan amplitudo, dan warp sinyal. Selain itu, fitur tambahan seperti statistik sinyal dan interval RR diekstraksi untuk memperkaya informasi input. Data kemudian diperiksa untuk memastikan tidak ada nilai yang hilang dan divisualisasikan guna memahami karakteristik sinyal, sebelum diseimbangkan agar jumlah sampel kedua kelas setara. Selanjutnya, data dipisah menjadi fitur dan label, lalu dibagi menjadi data pelatihan dan validasi dengan stratifikasi serta distandarisasi fitur. *Data augmentation* hanya diterapkan pada data pelatihan, sementara *class weight* dihitung untuk mengatasi ketidakseimbangan selama pelatihan. Model *deep neural network* yang digunakan mengadopsi arsitektur residual dengan lapisan *dense*, *batch normalization*, dan *dropout* guna meningkatkan stabilitas dan performa optimal. Proses pelatihan dilengkapi dengan *callback* seperti *EarlyStopping*, *ModelCheckpoint*, dan *ReduceLROnPlateau* untuk mencegah *overfitting* dan mengoptimalkan *learning rate*. Setelah pelatihan, performa model dipantau melalui grafik *loss* dan akurasi serta dievaluasi secara komprehensif menggunakan *classification report*, *confusion matrix*, MSE, ROC, *ROC curve*, *Precision-Recall curve*, dan distribusi *confidence*. Waktu inferensi per sampel yang tercatat sekitar 0,5 ms menunjukkan bahwa model ini cukup ringan dan layak diterapkan dalam sistem *real-time*. Akhirnya, model diuji dengan menampilkan sampel sinyal EKG acak beserta prediksi dan label sebenarnya untuk analisis manual dan *debugging*. Secara keseluruhan, model DNN ini menunjukkan performa sangat baik dalam mendeteksi kelainan jantung berdasarkan sinyal EKG pendek, dengan penggunaan teknik *balancing* data, normalisasi, dan *class weight* yang berkontribusi besar pada peningkatan akurasi dan kestabilan pelatihan. Potensi pengembangan lebih lanjut pada sistem *embedded* atau *mobile* sangat terbuka untuk mendukung diagnosis dini gangguan jantung secara efektif dan efisien.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa pengembangan sistem deteksi kelainan jantung berbasis *Deep Neural Network* (DNN) pada sinyal EKG memberikan hasil yang sangat memuaskan dan berpotensi besar untuk diimplementasikan dalam dunia medis. Model DNN yang dibangun dan dilatih menggunakan data *PTB Diagnostic ECG Database* (PTBDB) mampu mencapai akurasi validasi sebesar 95% dan nilai Area Under Curve (AUC) sebesar 0,98. Hasil ini menunjukkan bahwa model tidak hanya mampu membedakan secara efektif antara sinyal EKG normal dan abnormal, tetapi juga memiliki sensitivitas dan spesifisitas yang tinggi dalam mendeteksi kelainan jantung. Keunggulan utama dari pendekatan DNN terletak pada kemampuannya mengekstraksi fitur-fitur kompleks dari sinyal EKG secara otomatis, tanpa memerlukan proses pra-pemrosesan manual yang rumit, sehingga dapat mengurangi potensi kesalahan subjektif dalam interpretasi sinyal oleh tenaga medis. Selain itu, sistem ini dapat dioptimalkan untuk bekerja secara *real-time* dan terintegrasi dengan perangkat medis portabel, sehingga sangat relevan untuk diterapkan di wilayah dengan keterbatasan tenaga

medis dan fasilitas diagnostik, termasuk daerah terpencil di Indonesia. Meskipun demikian, penelitian ini juga memiliki beberapa keterbatasan yang perlu menjadi perhatian untuk pengembangan selanjutnya. Penggunaan dataset publik, meskipun sangat membantu dalam proses pelatihan dan validasi model, belum sepenuhnya merepresentasikan populasi pasien di Indonesia. Oleh karena itu, validasi lebih lanjut menggunakan data EKG lokal sangat diperlukan untuk memastikan robustnes dan generalisasi model di kondisi nyata. Selain itu, model DNN yang digunakan masih perlu dioptimalkan agar dapat dijalankan secara efisien pada perangkat portabel dengan sumber daya terbatas, serta perlu ditingkatkan dari aspek interpretabilitas agar hasil diagnosis dapat lebih mudah dipahami oleh tenaga medis.

REFERENCES

- [1] L. Farida Tampubolon, A. Ginting, F. Ermasta Saragi Turnip, Stik. Santa Elisabeth Medan, J. Bunga Terompet No, and K. Medan Selayang, "GAMBARAN FAKTOR YANG MEMPENGARUHI KEJADIAN PENYAKIT JANTUNG KORONER (PJK) DI PUSAT JANTUNG TERPADU (PJT)," 2023. [Online]. Available: <http://journal.stikeskendal.ac.id/index.php/PSKM>
- [2] M. Fajar and Z. Nugraha, "Deteksi Aritmia Menggunakan Algoritma Deep Neural Network (Dnn) Pada Sinyal Elektrokardiogram," 2023.
- [3] T. Mahmud *et al.*, "Ensemble Deep Learning Approach for ECG-Based Cardiac Disease Detection: Signal and Image Analysis," in *2023 International Conference on Information and Communication Technology for Sustainable Development, ICICT4SD 2023 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 70–74. doi: 10.1109/ICICT4SD59951.2023.10303625.
- [4] E. M. Marwali, Y. Purnama, P. S. Roebiono, K. : Eva, M. Marwali, and T. Pustaka, "Modalitas Deteksi Dini Penyakit Jantung Bawaan di Pelayanan Kesehatan Primer," 2021.
- [5] N. Alexandra Yosephine, "Penggunaan Artificial Neural Network pada Sinyal Elektrokardiogram untuk Mendeteksi Penyakit Jantung Aritmia Supraventrikular," 2021.
- [6] A. Riset, J. Raihanah Arkam, K. Wisudawan, A. Sitti Fahirah Arsal, and F. Sommeng, "FAKUMI MEDICAL JOURNAL Hubungan Faktor Resiko Penyakit Jantung terhadap Hasil Elektrokardiografi (EKG) pada Perawat UGD RS. Ibnu Sina," 2023.
- [7] W. Samek, G. Montavon, S. Lapuschkin, C. J. Anders, and K. R. Müller, "Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications," *Proceedings of the IEEE*, vol. 109, no. 3, pp. 247–278, Mar. 2021, doi: 10.1109/JPROC.2021.3060483.
- [8] Y. Julia Nurrisi, "Optimasi Deep Convolutional Neural Network (Deep CNN) untuk Deteksi Aritmia Melalui Sinyal EKG Menggunakan Arsitektur Conv1D," 2023. [Online]. Available: <http://journal.unnes.ac.id/nju/index.php/JM>
- [9] R. N. P. P. Irpanudin. Reka. Anggraeni, "PREDIKSI PENYAKIT JANTUNG MENGGUNAKAN METODE DEEP NEURAL NETWORK DENGAN MEMANFAATKAN INTERNET OF THINGS," 2023.
- [10] A. Çınar and S. A. Tuncer, "Classification of normal sinus rhythm, abnormal arrhythmia and congestive heart failure ECG signals using LSTM and hybrid CNN-SVM deep neural networks," *Comput Methods Biomech Biomed Engin*, vol. 24, no. 2, pp. 203–214, 2021, doi: 10.1080/10255842.2020.1821192.
- [11] T. R. Setyawan, T. K. Wibowo, A. Hidayatno, and E. Handoyo, "PERANCANGAN ALAT DETEKSI KELAINAN JANTUNG DENGAN ANALISIS HASIL EKG BERBASIS MACHINE LEARNING," 2024. [Online]. Available: <https://ejournal3.undip.ac.id/index.php/transient>
- [12] K. Wickstrøm, M. Kampffmeyer, and R. Jenssen, "Uncertainty and interpretability in convolutional neural networks for semantic segmentation of colorectal polyps," *Med Image Anal*, vol. 60, Feb. 2020, doi: 10.1016/j.media.2019.101619.
- [13] A. H. Khan, M. Hussain, and M. K. Malik, "Cardiac disorder classification by electrocardiogram sensing using deep neural network," *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/5512243.
- [14] S. E. M. E. S. S. B. P. A. D. Praptinasari, "Sistem Deteksi Kelainan Jantung Berdasarkan Elektrokardiograf Secara Otomatis," *Journal of Electrical Electronic Control and Automotive Engineering (JEECAE)*, vol. 7, no. 1, 2022.
- [15] M. Hammad, A. Maher, K. Wang, F. Jiang, and M. Amrani, "Detection of abnormal heart conditions based on characteristics of ECG signals," *Measurement (Lond)*, vol. 125, pp. 634–644, Sep. 2018, doi: 10.1016/j.measurement.2018.05.033.
- [16] H. Pham, K. Egorov, A. Kazakov, and S. Budenny, "Machine learning-based detection of cardiovascular disease using ECG signals: performance vs. complexity," *Front Cardiovasc Med*, vol. 10, 2023, doi: 10.3389/fcvm.2023.1229743.



- [17] I. J. S, M. M, and S. K. K, “Detection and Classification of electrocardiography using hybrid deep learning models,” *Hellenic Journal of Cardiology*, Jan. 2024, doi: 10.1016/j.hjc.2024.08.011.
- [18] D. R. Giri, K. S. V. Ram, K. Vijendra, G. D. Babu, and D. D. S. Ganesh, “Detection of Cardiovascular Diseases through ECG Images,” *International Journal of Innovative Research in Computer Science and Technology*, vol. 13, no. 2, pp. 72–78, Apr. 2025, doi: 10.55524/ijircst.2025.13.2.11.
- [19] A. Gour, M. Gupta, R. Wadhvani, and S. Shukla, “ECG Based Heart Disease Classification: Advancement and Review of Techniques,” in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 1634–1648. doi: 10.1016/j.procs.2024.04.155.
- [20] S. Ahmed, A. Hilal-Alnaqbi, M. Al Hemaury, and M. Al Ahmad, “ECG Abnormality Detection Algorithm,” 2018. [Online]. Available: www.ijacsa.thesai.org