



Klasifikasi Aritmia Berbasis Model Hybrid Convolutional Neural Network dan Transformer dengan Implementasi Berbasis Web

Jibril Muhammad Arief¹, Cahyono Budy Santoso^{2,*}

Fakultas Teknologi dan Desain, Sistem Informasi, Universitas Pembangunan Jaya, Tangerang Selatan, Indonesia

Email: ¹jibril.muhammadarief@student.upj.ac.id, ^{2,*}cahyono.budy@upj.ac.id

Email Penulis Korespondensi: cahyono.budy@upj.ac.id

Abstrak—Aritmia jantung merupakan kelainan irama detak jantung yang dapat memicu gangguan kardiovaskular serius serta meningkatkan risiko kematian mendadak. Proses deteksi aritmia secara konvensional masih mengandalkan interpretasi manual sinyal elektrokardiogram (EKG) oleh tenaga medis, sehingga membutuhkan ketelitian tinggi dan waktu analisis yang cukup lama. Kemajuan teknologi kecerdasan buatan, khususnya pada bidang Deep Learning, telah membuka peluang bagi pengembangan sistem deteksi otomatis yang lebih cepat dan konsisten. Penelitian ini mengusulkan model klasifikasi aritmia berbasis arsitektur hybrid Convolutional Neural Network (CNN) dan Transformer. CNN digunakan untuk mengekstraksi fitur spasial dari sinyal EKG, sedangkan Transformer berfungsi memahami pola temporal yang terdapat pada rangkaian sinyal tersebut. Dataset MIT-BIH Arrhythmia digunakan dalam proses pelatihan dan validasi yang mencakup lima kelas detak jantung, yaitu Normal, Supraventricular, Ventricular, Fusion, dan Unknown beats. Hasil pengujian menunjukkan bahwa model mampu mencapai akurasi validasi sebesar 98 persen disertai nilai precision, recall, dan F1-score yang seimbang pada kelas mayoritas. Lebih lanjut, model menunjukkan keandalan pada kelas minoritas yang kritis dengan mencatatkan nilai sensitivitas (recall) sebesar 93,7% untuk kelas Ventricular dan 57,1% untuk kelas Supraventricular. Model ini kemudian diimplementasikan ke dalam sistem berbasis web untuk memungkinkan analisis sinyal EKG secara real-time dan fleksibel. Hasil ini mengindikasikan bahwa integrasi CNN dan Transformer efektif dalam meningkatkan akurasi deteksi aritmia, tidak hanya pada kelas mayoritas tetapi juga pada kelas patologi yang jarang muncul.

Kata Kunci: Aritmia; Elektrokardiogram; CNN; Transformer; Deep Learning; Sistem Berbasis Web

Abstract—Cardiac arrhythmia is a heart rhythm disorder that can trigger serious cardiovascular conditions and significantly increase the risk of sudden cardiac death. Conventional arrhythmia detection processes still rely on the manual interpretation of electrocardiogram (ECG) signals by medical experts, which necessitates high precision and is time-consuming. Advancements in artificial intelligence, particularly in Deep Learning, have paved the way for the development of faster and more consistent automated detection systems. This study proposes an arrhythmia classification model based on a hybrid architecture combining Convolutional Neural Networks (CNN) and Transformers. The CNN is utilized to extract spatial features from ECG signals, while the Transformer functions to capture temporal patterns within the signal sequences. The MIT-BIH Arrhythmia Database was employed for training and validation, encompassing five heartbeat classes: Normal, Supraventricular, Ventricular, Fusion, and Unknown beats. Experimental results demonstrate that the model achieved a validation accuracy of 98%, accompanied by balanced precision, recall, and F1-scores for the majority class. Furthermore, the model demonstrated robustness in detecting critical minority classes, achieving a sensitivity (recall) of 93.7% for Ventricular beats and 57.1% for Supraventricular beats. This model was subsequently implemented into a web-based system to enable real-time and flexible ECG signal analysis. These findings indicate that the integration of CNN and Transformer effectively enhances arrhythmia detection accuracy, not only for majority classes but also for rare pathological classes.

Keywords: Arrhythmia; ECG; CNN; Transformer; Deep Learning; Web-Based System

1. PENDAHULUAN

Aritmia jantung merupakan kelainan irama detak jantung yang dapat memicu gangguan kardiovaskular serius dan berkontribusi signifikan terhadap mortalitas global. Studi menunjukkan bahwa penyakit kardiovaskular bertanggung jawab atas 30% kematian di dunia, di mana 25% di antaranya dikategorikan sebagai kematian jantung mendadak yang sering kali terjadi dalam waktu kurang dari satu jam sejak timbulnya gejala (Chandra & Suwanto, 2021). Gangguan ini terjadi ketika impuls listrik jantung tidak berjalan secara normal sehingga menghasilkan detak yang terlalu cepat (takikardia), terlalu lambat (bradikardia), atau tidak beraturan. Pada praktik klinis, deteksi aritmia paling umum dilakukan melalui pemeriksaan elektrokardiogram (EKG), yaitu representasi aktivitas listrik jantung dalam bentuk sinyal. Namun, metode konvensional ini memiliki keterbatasan signifikan karena hanya mampu merekam aktivitas jantung dalam durasi singkat (sekitar 10 detik hingga 1 menit), sehingga sering kali gagal menangkap aritmia yang bersifat paroksismal (muncul sewaktu-waktu) atau *silent ischemia* yang tidak menunjukkan gejala saat pemeriksaan berlangsung. Meskipun EKG merupakan metode diagnosis standar, interpretasi terhadap sinyal tersebut tetap membutuhkan tenaga medis yang terlatih, karena pola gelombang yang muncul memiliki variasi morfologi yang kompleks dan etiologi yang beragam bergantung pada usia pasien, mulai dari *channelopathies* pada usia muda hingga penyakit jantung koroner pada populasi lanjut usia (Chandra & Suwanto, 2021). Ketergantungan terhadap keahlian individu inilah yang menyebabkan analisis dapat berlangsung lama dan berpotensi menghasilkan ketidakakuratan antar evaluator, terutama pada fasilitas kesehatan dengan keterbatasan tenaga ahli atau tingginya beban kerja (Chandra & Suwanto, 2021; Narendra, Sakti Pramukantoro, & Amron, 2025). Permasalahan ini semakin relevan mengingat fakta bahwa 50% kasus henti jantung terjadi pada individu tanpa riwayat penyakit jantung sebelumnya, yang mengindikasikan tingginya prevalensi *silent ischemia*. Oleh karena itu, pengembangan sistem deteksi dini yang mudah diakses menjadi krusial sebagai upaya pencegahan primer (Chandra & Suwanto, 2021).



Dalam dua dekade terakhir, perkembangan kecerdasan buatan, khususnya pada bidang *deep learning*, telah membuka peluang besar dalam pengembangan sistem klasifikasi aritmia otomatis. Berbagai penelitian telah menerapkan *Deep Neural Network* (DNN) untuk mendeteksi pola kompleks sinyal EKG dan menunjukkan performa yang cukup baik pada beberapa jenis aritmia (Fajar & Nugraha, 2023; Ratna Lestari Budiani Buana & Imroatul Hudati, 2022). Namun, arsitektur DNN tradisional masih menghadapi keterbatasan dalam menangkap pola sekuensial jangka panjang yang menjadi karakteristik penting dari sinyal EKG, terutama pada aritmia yang memiliki variasi temporal yang tidak konstan. *Convolutional Neural Network* (CNN) kemudian muncul sebagai solusi yang lebih unggul dalam mengekstraksi fitur spasial, misalnya bentuk gelombang P, kompleks QRS, dan gelombang T, sehingga banyak digunakan dalam klasifikasi sinyal biomedis. Meskipun demikian, CNN secara alami tidak dirancang untuk memahami dinamika temporal yang panjang. Studi terbaru menegaskan bahwa meskipun CNN efektif menangkap pola spasial lokal, arsitektur ini kesulitan mempelajari urutan temporal atau dependensi jangka panjang pada data *time-series* seperti EKG, sehingga integrasi dengan model yang memiliki mekanisme atensi menjadi solusi yang diperlukan (Putra et al., 2021).

Sebaliknya, *Transformer* sebagai arsitektur berbasis mekanisme *self-attention* telah menunjukkan performa yang sangat baik dalam pemrosesan data sekuensial. Pendekatan ini bekerja dengan menilai hubungan antarposisi dalam urutan *input* secara langsung, tanpa ketergantungan pada urutan spasial seperti pada CNN atau urutan rekursif seperti pada LSTM. Hal ini membuat *Transformer* mampu menangkap dependensi jangka panjang secara lebih efektif dan efisien. Sejumlah penelitian menunjukkan bahwa *Transformer* memiliki kemampuan tinggi dalam mempelajari pola jangka panjang pada sinyal biomedis, termasuk sinyal EKG, sehingga dapat meningkatkan akurasi dan stabilitas model dalam mendeteksi berbagai jenis detak jantung abnormal (Hao et al., 2025; Kim et al., 2025). Dengan demikian, integrasi CNN dan *Transformer* menjadi pendekatan hibrida yang menjanjikan. Hal ini sejalan dengan tinjauan literatur terkini yang menyimpulkan bahwa model hibrida, di mana CNN berfungsi sebagai pengekstraksi fitur awal yang dilanjutkan dengan pemrosesan sekuensial, secara konsisten menunjukkan performa yang lebih unggul dibandingkan arsitektur *Deep Learning* tunggal atau tradisional (Ansari, Mourad, Qaraqe, & Serpedin, 2023). Sinergi ini krusial, di mana CNN bertugas membangun representasi spasial awal dari fitur lokal, sementara *Transformer* memperkaya representasi tersebut dengan informasi temporal global. Validitas pendekatan ini didukung oleh studi ablasi yang menunjukkan bahwa menghilangkan salah satu modul baik CNN maupun *Transformer* dapat mengakibatkan penurunan performa model yang signifikan, menegaskan komplementaritas kedua arsitektur tersebut dalam menangkap pola data yang kompleks (Hao et al., 2025). Model *hybrid* ini memungkinkan sistem mempelajari fitur sinyal EKG secara lebih holistik, yaitu dari sisi bentuk gelombang dan dari sisi dinamika temporal.

Di samping pengembangan arsitektur model yang lebih akurat, aspek implementasi sistem juga menjadi perhatian penting agar hasil penelitian dapat diterapkan secara lebih luas dan memberikan dampak nyata. Penelitian sebelumnya menunjukkan bahwa sistem analisis EKG berbasis web dan cloud tidak hanya unggul dalam aksesibilitas, tetapi juga menawarkan fleksibilitas sumber daya melalui mekanisme penskalaan otomatis (*autoscaling*) untuk menangani fluktuasi permintaan inferensi yang besar secara efisien (Narendra et al., 2025). Dengan platform berbasis web, pengguna dapat mengunggah sinyal EKG dan memperoleh hasil prediksi secara *real-time* tanpa instalasi aplikasi khusus. Pendekatan ini terbukti meningkatkan efektivitas pengelolaan data serta memberikan fleksibilitas akses yang lebih tinggi dibandingkan sistem berbasis *desktop* konvensional (Rangga Wahyu Pratama, Paskah Abadi Simanullang, Peter Tymoty Hutabarat, Revidamurti Daulay, & Adidtya Perdana, 2025). Sistem berbasis web ini menawarkan alternatif yang lebih aksesibel untuk skrining awal dibandingkan metode konvensional seperti *holter monitoring* atau *implantable loop recorder* yang biasanya memerlukan prosedur klinis lebih kompleks. Dengan demikian, platform ini dapat mendukung strategi deteksi dini untuk mencegah kematian mendadak akibat aritmia (Chandra & Suwanto, 2021).

Urgensi penelitian ini semakin kuat ketika mempertimbangkan fakta bahwa dataset EKG, khususnya MIT-BIH Arrhythmia Database, memiliki variasi sinyal yang cukup luas sehingga memungkinkan pengembangan model klasifikasi yang lebih *robust*. Model yang dikembangkan tidak hanya harus mampu mengenali kelas mayoritas seperti *Normal beats*, tetapi juga kelas minoritas seperti *Supraventricular beats* dan *Fusion beats* yang jauh lebih sulit dideteksi. Ketidakseimbangan data ini menuntut penerapan teknik augmentasi dan penyeimbangan data yang tepat agar model tidak bias terhadap kelas tertentu. Selain itu, evaluasi performa model dilakukan secara komprehensif menggunakan metrik standar. Hal ini krusial mengingat tinjauan sistematis terbaru menunjukkan bahwa banyak studi literatur cenderung melaporkan akurasi yang terlalu optimis akibat penggunaan skema evaluasi intra-patient yang mencampurkan data pasien yang sama dalam proses pelatihan dan pengujian, sehingga gagal merefleksikan performa klinis yang sesungguhnya (Silva et al., 2025).

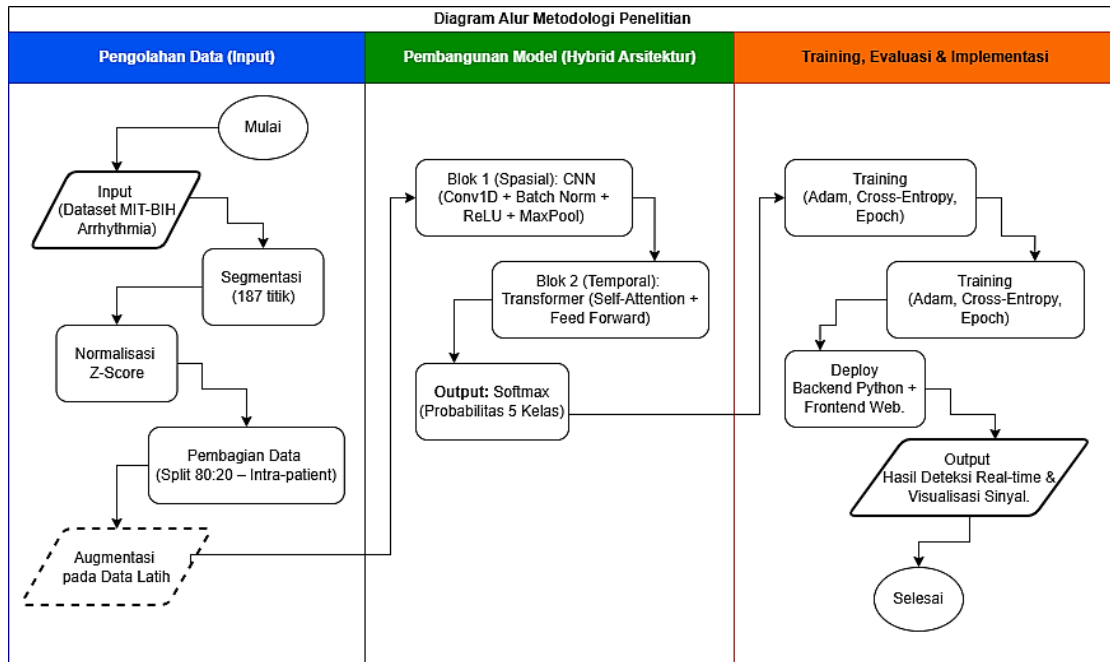
Berdasarkan latar belakang tersebut, penelitian ini memiliki tiga tujuan utama. Pertama, mengembangkan model *hybrid* CNN dan *Transformer* yang mampu mempelajari fitur spasial dan temporal sinyal EKG secara bersamaan guna meningkatkan akurasi, stabilitas, serta ketahanan model dalam mengklasifikasikan berbagai jenis aritmia, termasuk kelas minoritas yang secara klinis penting namun sulit terdeteksi. Kedua, mengevaluasi performa model secara komprehensif menggunakan metrik evaluasi standar seperti akurasi, precision, recall, F1-score, serta analisis kurva ROC, sehingga kualitas prediksi dan kemampuan generalisasi model dapat diukur secara objektif dan lebih merepresentasikan kondisi klinis nyata. Ketiga, mengimplementasikan model yang telah dikembangkan ke dalam sebuah platform berbasis web yang mudah diakses dan bersifat user-friendly, sehingga hasil penelitian tidak hanya berhenti pada tataran teoretis, tetapi juga dapat dimanfaatkan secara praktis sebagai alat bantu skrining awal dan media pendukung pembelajaran. Implementasi berbasis web ini diharapkan mampu menjembatani kesenjangan antara hasil

penelitian dan kebutuhan pengguna, baik di lingkungan akademik maupun layanan kesehatan, dengan menyediakan sistem yang fleksibel, responsif, dan efisien. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi nyata dalam pengembangan sistem deteksi aritmia otomatis yang lebih akurat, cepat, dan andal, serta mendorong pemanfaatan kecerdasan buatan sebagai solusi inovatif yang berpotensi meningkatkan kualitas pengambilan keputusan medis dan upaya pencegahan dini gangguan kardiovaskular secara berkelanjutan.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

Penelitian ini disusun menggunakan pendekatan eksperimental kuantitatif yang berfokus pada pengembangan dan pengujian model klasifikasi aritmia berbasis arsitektur *hybrid CNN* dan *Transformer*. Fokus utama penelitian ini adalah melakukan pemodelan sinyal elektrokardiogram (EKG) dari dataset MIT-BIH Arrhythmia Database untuk mengidentifikasi pola kelainan detak jantung secara otomatis. Kerangka dasar penelitian ini dirancang untuk memastikan bahwa proses pemodelan berlangsung sistematis, reproduisibel, serta memenuhi standar metodologi penelitian berbasis *deep learning* yang umum diterapkan dalam analisis sinyal biomedis. Seluruh rangkaian penelitian dimulai dari kajian literatur, pengumpulan dataset, *preprocessing* sinyal, pengembangan model, pelatihan model, evaluasi, serta penyusunan implementasi berbasis web sebagai bentuk penerapan seperti yang ditunjukkan di Gambar 1.



Gambar 1. Diagram Alur Metodologi Penelitian

Landasan teoritis penelitian ini didasarkan pada karakteristik sinyal EKG yang memiliki struktur spasial (morfologi gelombang) dan temporal (urutan waktu) yang kuat. Pendekatan *Deep Learning* dipilih karena kemampuannya mempelajari pola data secara langsung tanpa ekstraksi fitur manual yang kaku (Fajar & Nugraha, 2023; Putra et al., 2021). Pendekatan ini mengatasi kelemahan metode tradisional yang bergantung pada *handcrafted features* (seperti koefisien wavelet), yang sering kali memiliki kemampuan generalisasi yang buruk pada database besar dan sangat bergantung pada rekayasa manual yang rentan bias (Ikram et al., 2025). Arsitektur CNN digunakan untuk mengekstraksi fitur spasial lokal secara otomatis dari data mentah, sedangkan *Transformer* diintegrasikan untuk memodelkan hubungan temporal global antar titik sinyal. Mekanisme *self-attention* pada *Transformer* memungkinkan model merespons aspek kritis di seluruh urutan sinyal secara simultan, mengatasi keterbatasan model sekuensial biasa dalam menangkap dependensi jangka panjang (Ansari et al., 2023).

Dataset MIT-BIH memiliki lima kelas utama yaitu *Normal beats*, *Supraventricular beats*, *Ventricular beats*, *Fusion beats*, dan *Unknown beats*. Keragaman kategori ini menjadi tantangan tersendiri karena sebagian kelas memiliki jumlah sampel yang jauh lebih sedikit dibanding kelas mayoritas. Kerangka dasar penelitian ini mengakomodasi permasalahan ketidakseimbangan tersebut melalui penerapan teknik augmentasi sinyal pada data latih. Teknik *jittering* diterapkan dengan menambahkan *noise* acak berdistribusi Gaussian dengan standar deviasi 0.01, sedangkan *scaling* dilakukan dengan memvariasikan magnitudo sinyal menggunakan faktor skala acak dalam rentang 0.8 hingga 1.2 guna mengakomodasi variabilitas fisiologis antar pasien. Selain itu, normalisasi z-score diterapkan untuk memastikan keseragaman skala dan menghilangkan bias akibat variasi amplitudo atau *baseline drift* (Lamba, Kumar, & Diwakar, 2025).



Tahapan penelitian ditutup dengan evaluasi performa model menggunakan metrik akurasi, *precision*, *recall*, *F1-score*, matriks konfusi, serta kurva ROC untuk menilai performa per kelas. Setelah evaluasi dilakukan, seluruh hasil dianalisis secara menyeluruh untuk menilai efektivitas arsitektur yang digunakan, mengidentifikasi kelemahan, dan merumuskan rekomendasi untuk penelitian selanjutnya. Alur penelitian yang sistematis ini memastikan bahwa proses pengembangan model dilakukan secara terstruktur, objektif, dan sesuai dengan kaidah penelitian ilmiah. Penerapan metode berbasis Deep Learning dalam analisis sinyal biomedis semakin relevan, di mana studi terbaru menunjukkan bahwa model seperti CNN mampu mengklasifikasikan berbagai jenis aritmia dari sinyal EKG dengan akurasi yang sebanding dengan kardiolog bersertifikat, sehingga memvalidasi potensi penggunaannya dalam sistem diagnosis otomatis (Mienye & Swart, 2024).

2.2 Metode Pengumpulan Data

Tahapan penelitian dirancang sistematis sesuai standar analisis sinyal biomedis, diawali dengan penyiapan dataset *MIT-BIH Arrhythmia* yang mencakup lima kelas: *Normal*, *Supraventricular*, *Ventricular*, *Fusion*, dan *Unknown beats*. Setiap sampel terdiri dari 187 titik data yang mewakili satu detak jantung utuh. Rincian karakteristik dataset, distribusi jumlah sampel per kelas, dan visualisasi statistik data yang digunakan dalam eksperimen ini akan dipaparkan secara mendalam pada Sub-bab 3.1.

Data mentah EKG sering kali terkontaminasi oleh *noise* akibat interferensi daya, *baseline-drifts*, kontraksi otot, maupun aktivitas pernapasan. Oleh karena itu, tahap *preprocessing* yang ketat diperlukan untuk meminimalkan gangguan tersebut sebelum fitur diekstraksi oleh model. Langkah ini krusial mengingat karakteristik sinyal EKG yang lemah dan stokastik membuatnya sangat rentan terhadap interferensi, sehingga strategi pra-pemrosesan yang tepat diperlukan untuk menjaga integritas fitur sebelum ekstraksi (Bai, Dong, Li, Liu, & Zhang, 2024). Penelitian terkini menunjukkan bahwa penerapan teknik pra-pemrosesan yang efektif pada tahap awal secara signifikan berkontribusi terhadap tingginya akurasi klasifikasi akhir dengan menjaga integritas fitur morfologis sinyal (Fajar & Nugraha, 2023; Ikram et al., 2025). Secara spesifik, penelitian ini menerapkan teknik Normalisasi Z-Score untuk menstandarisasi distribusi sinyal sehingga memiliki rata-rata nol dan variansi satu. Teknik ini dipilih karena kemampuannya menekan dampak variasi amplitudo dan *baseline wander* tanpa risiko menghilangkan informasi detail pada segmen mikro yang mungkin terjadi pada penggunaan filter frekuensi agresif, serta memanfaatkan ketahanan intrinsik (*intrinsic robustness*) dari arsitektur CNN terhadap gangguan frekuensi tinggi.

Pasca-*preprocessing*, dataset dibagi menjadi data latih (80%) dan data validasi (20%) untuk menjamin objektivitas evaluasi pada data yang belum pernah dilihat (*unseen data*). Pelatihan dilakukan menggunakan *Dataloader* dengan mekanisme *shuffle* (pengacakan) untuk mencegah bias urutan. Selanjutnya, arsitektur model dibangun secara bertahap: (1) Blok CNN (tiga lapisan konvolusi, *Batch Norm*, ReLU, *Max Pooling*) untuk mengekstraksi fitur spasial lokal; (2) Blok Transformer (*Self-Attention*) untuk menangkap dependensi temporal jangka panjang; dan (3) Lapisan Output (*Global Average Pooling* dan *Fully Connected*) untuk klasifikasi akhir.

Proses pelatihan menggunakan *optimizer* Adam dan fungsi *loss Cross Entropy*, di mana model terbaik disimpan secara otomatis berdasarkan *loss* terendah pada setiap *epoch*. Pemantauan ketat ini dilakukan karena studi literatur menegaskan bahwa optimalisasi *hyperparameter*, khususnya pengaturan jumlah *epoch* dan tingkat pembelajaran (*learning rate*) yang presisi, terbukti berkontribusi signifikan dalam meningkatkan efisiensi komputasi sekaligus mencegah terjadinya *overfitting* (Insan, Khotimah, Yudistira, & Ardiansyah, 2024). Metodologi ditutup dengan evaluasi komprehensif menggunakan data validasi, meliputi analisis matriks konfusi, kurva ROC, serta metrik *precision*, *recall*, dan *F1-score* guna memastikan keandalan model sebelum diimplementasikan ke dalam platform berbasis *web*.

2.3 Implementasi Model Hybrid CNN dan Transformer

Implementasi model hybrid ini dilakukan menggunakan framework PyTorch yang menggabungkan kemampuan ekstraksi fitur spasial dari Convolutional Neural Network (CNN) dan pemodelan dependensi temporal dari Transformer. Arsitektur CNN dipilih karena keunggulannya dalam *local connectivity* dan *weight sharing*, yang menurut studi literatur terbaru terbukti sangat efektif dalam mengekstraksi fitur morfologis lokal dari sinyal EKG yang kompleks dibandingkan arsitektur *fully-connected* tradisional (Wu & Guo, 2025). Tahap awal dimulai dengan blok CNN yang menerapkan operasi konvolusi 1D pada sinyal EKG. Secara matematis, operasi ini dinyatakan dalam Persamaan (1):

$$Z(t) = \text{ReLU}(W * X(t) + b) \quad (1)$$

dengan $X(t)$ adalah sinyal input, W adalah kernel, dan b adalah bias. Fungsi aktivasi ReLU digunakan untuk mempercepat konvergensi dan mengatasi *vanishing gradient* (Mienye & Swart, 2024). Model menggunakan tiga lapisan konvolusi bertingkat (64, 128, 256 filter) yang dilengkapi dengan *Batch Normalization* dan *Max Pooling* untuk membangun representasi fitur hierarkis yang stabil.

Output CNN kemudian diproyeksikan ke dalam blok *Transformer* yang memanfaatkan mekanisme *multi-head self-attention*. Mekanisme ini memungkinkan model menangkap hubungan global antar segmen sinyal, sebagaimana diformulasikan dalam Persamaan (2). Integrasi mekanisme atensi ini sejalan dengan temuan terbaru Zhou dan Fang, yang membuktikan bahwa penyematan modul atensi pada arsitektur CNN secara signifikan meningkatkan sensitivitas model terhadap fitur-fitur mikro yang sering terabaikan oleh operasi konvolusi standar, sehingga menghasilkan akurasi klasifikasi yang lebih superior pada dataset aritmia yang kompleks (Zhou & Fang, 2024):



$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2)$$

Dengan Q (query), K (key), dan V (value) adalah proyeksi linear dari fitur input. Penelitian ini menggunakan konfigurasi empat *head attention* yang diperkuat dengan *feed-forward network* dan *residual connection* untuk memastikan aliran informasi yang optimal. Efisiensi arsitektur ini juga telah divalidasi oleh Alghieth, yang mendemonstrasikan bahwa model *hybrid* berbasis Transformer tidak hanya unggul dalam representasi fitur global, tetapi juga sangat efisien secara komputasi (*low memory footprint*), menjadikannya kandidat ideal untuk penyebaran pada sistem diagnosis *real-time* berbasis perangkat terbatas (Alghieth, 2025).

Fitur hasil pemrosesan kemudian diringkas melalui *Global Average Pooling* dan diklasifikasikan oleh lapisan *fully connected* menggunakan fungsi aktivasi *Softmax* untuk mendapatkan probabilitas kelas $\hat{y}_i$, seperti ditunjukkan pada Persamaan (3):

$$\hat{y}_i = \frac{e^{z_i}}{\sum_{j=1}^5 e^{z_j}} \quad (3)$$

Proses pelatihan dijalankan menggunakan *optimizer* Adam dengan *learning rate* 0.001 dan fungsi objektif *Cross Entropy Loss* untuk meminimalkan kesalahan prediksi, yang dinyatakan dalam Persamaan (4):

$$L = \sum_{i=1}^5 y_i \log \hat{y}_i \quad (4)$$

Pemilihan konfigurasi *hyperparameter* ini didasarkan pada studi literatur untuk mencegah *overfitting* sekaligus mencapai akurasi optimal (Bai et al., 2024). Seluruh proses pelatihan hingga penyimpanan model terbaik diotomatisasi dalam sebuah *pipeline* untuk menjamin reproduktibilitas hasil eksperimen.

2.4 Metode Evaluasi Model

Evaluasi performa model bertujuan untuk mengukur kemampuan klasifikasi secara komprehensif menggunakan metrik standar, yaitu akurasi, *precision*, *recall*, *F1-score*, matriks konfusi, dan kurva ROC. Mengingat adanya ketidakseimbangan kelas yang signifikan pada dataset MIT-BIH, penggunaan metrik akurasi semata tidak cukup untuk merefleksikan kinerja model yang sebenarnya. Oleh karena itu, penelitian ini menitikberatkan pada nilai *precision* dan *recall* untuk mengukur relevansi dan sensitivitas model, serta *F1-score* sebagai rata-rata harmonik keduanya guna memberikan penilaian yang adil terhadap performa kelas minoritas maupun mayoritas. Strategi evaluasi ini sejalan dengan standar terbaru yang diterapkan menunjukkan bahwa pada klasifikasi aritmia multikelas, pelaporan *F1-Score* memberikan indikasi performa yang jauh lebih representatif dibanding akurasi global, terutama untuk membedakan kategori patologis kritis seperti Infark Miokard (MI) (Cheng, Yi, & Peng, 2025). Hal ini juga didukung oleh Madan et al. yang menekankan keseimbangan Sensitivitas dan Spesifisitas untuk meminimalkan risiko kesalahan diagnosis klinis (Madan et al., 2022).

Analisis mendalam dilakukan menggunakan *Confusion Matrix* yang merinci hasil prediksi untuk kelima kelas (N, S, V, F, Q). Pendekatan pelaporan per kelas ini diadopsi sesuai pedoman standar dalam literatur terkini untuk menghindari bias evaluasi dan memastikan transparansi kemampuan deteksi pada kelas kritis yang sering terabaikan, seperti *Supraventricular* dan *Fusion beats* (Silva et al., 2025). Pentingnya rincian evaluasi ini juga dikonfirmasi oleh Sibarani et al., yang menunjukkan bahwa penggunaan matriks konfusi adalah satu-satunya cara valid untuk memverifikasi apakah peningkatan akurasi global benar-benar mencerminkan perbaikan deteksi pada kelas minoritas atau sekadar bias terhadap kelas mayoritas (Sibarani, Pasaribula, Maduwu, Panggabean, & Aisyah, 2025). Selain itu, Kurva *Receiver Operating Characteristic* (ROC) dan nilai *Area Under Curve* (AUC) digunakan untuk mengukur kemampuan diskriminasi model dalam memisahkan antar kelas pada berbagai ambang batas (*threshold*) probabilitas, sehingga memberikan gambaran utuh mengenai ketahanan (*robustness*) model yang dikembangkan.

3. HASIL DAN PEMBAHASAN

3.1 Data Penelitian

Data penelitian yang digunakan dalam studi ini berasal dari *MIT-BIH Arrhythmia Database*, yaitu salah satu dataset referensi internasional yang paling banyak digunakan dalam pengembangan dan evaluasi sistem klasifikasi aritmia berbasis sinyal elektrokardiogram (EKG) (Silva et al., 2025). Dataset ini dikembangkan oleh *Beth Israel Hospital* dan MIT, serta telah divalidasi secara klinis sehingga menjadi standar *benchmark* bagi penelitian-penelitian dalam bidang analisis sinyal jantung. Secara spesifik, dataset ini terdiri dari 48 rekaman sinyal dua saluran (*two-channel*) berdurasi 30 menit yang diambil dari 47 subjek, dengan frekuensi pencuplikan (*sampling rate*) 360 Hz dan resolusi 11-bit pada rentang 10 mV. Keunggulan MIT-BIH terletak pada keragaman morfologi sinyalnya, keberagaman tipe aritmia, dan kualitas perekaman yang stabil, sehingga sangat sesuai digunakan dalam pengembangan model berbasis *deep learning*.

Dalam penelitian ini digunakan total 109.446 sampel sinyal EKG, di mana setiap sampel merupakan hasil segmentasi *heartbeat* yang telah distandarkan menjadi 187 titik data. Segmentasi ini berfungsi untuk menyelaraskan panjang sinyal sehingga setiap *input* merepresentasikan satu siklus detak jantung utuh. Pendekatan ini mengacu pada teknik segmentasi berbasis puncak R yang mencakup durasi sebelum dan sesudah puncak R. Meskipun penelitian



terkini mulai mengeksplorasi metode klasifikasi tanpa identifikasi R-peak untuk menghindari kegagalan deteksi pada aritmia kompleks, segmentasi berbasis R-peak tetap menjadi standar yang andal untuk memastikan gelombang P, kompleks QRS, dan gelombang T terekam secara lengkap dalam satu *beat* (Kim et al., 2025; Putra et al., 2021). Dengan segmentasi seragam ini, model dapat melakukan pembelajaran secara konsisten terhadap pola fisiologis yang membedakan detak normal dan detak abnormal.

Setiap sampel diberikan label sesuai kategori aritmia standar yang terdiri dari lima kelas, yaitu *Normal beats* (N), *Supraventricular ectopic beats* (S), *Ventricular ectopic beats* (V), *Fusion beats* (F), dan *Unknown beats* (Q). Distribusi data pada penelitian ini menunjukkan ketidakseimbangan yang signifikan, dengan rincian jumlah sampel sebagai berikut: *Normal* (N) mendominasi dengan 90.589 sampel, diikuti oleh *Unknown* (Q) 8.039 sampel, *Ventricular* (V) 7.236 sampel, *Supraventricular* (S) 2.779 sampel, dan *Fusion* (F) hanya 803 sampel. Pembagian kelas ini mengacu pada pedoman standar AAMI. Kepatuhan terhadap standar ini menjadi nilai tambah yang signifikan, mengingat studi literatur terbaru mengungkapkan bahwa hanya sekitar 55% penelitian klasifikasi aritmia yang benar-benar mengikuti pedoman pengelompokan kelas AAMI, yang menyebabkan inkonsistensi dalam perbandingan performa antar model (Silva et al., 2025). Dataset MIT-BIH diakui sebagai basis data yang sangat kuat (*powerful*) dan menjadi standar acuan dalam penelitian aritmia. Namun, penggunaan data ini menuntut tahapan *preprocessing* yang rumit dan tepat karena karakteristiknya sebagai data mentah yang kompleks serta adanya ketidakseimbangan kelas yang dapat memengaruhi efektivitas data latih (Ratna Lestari Budiani Buana & Imroatul Hudati, 2022).

Dataset diperoleh dalam format CSV yang memuat amplitudo sinyal EKG untuk setiap titik waktu serta label kelas pada kolom terakhir. Proses awal meliputi penghapusan nilai kosong, verifikasi ulang integritas sinyal, validasi bentuk gelombang, serta pengecekan apakah setiap sampel memenuhi panjang minimal untuk proses interpolasi apabila diperlukan. Selanjutnya data dikonversi ke dalam array numerik dan diproses melalui fungsi *preprocessing* yang tersedia pada skrip *PyTorch* penelitian ini. Seluruh data dipastikan berada dalam rentang representatif sehingga mampu mendukung proses pembelajaran model *hybrid CNN* dan *Transformer* secara optimal dan bebas dari bias sinyal. Keberagaman dan kualitas data MIT-BIH menjadi fondasi penting dalam pengembangan model klasifikasi aritmia yang tidak hanya akurat, tetapi juga *robust* terhadap variasi sinyal fisiologis individu.


3.2 Hasil Pelatihan Model

Proses pelatihan model *hybrid CNN Transformer* menunjukkan dinamika pembelajaran yang stabil dan progresif selama sembilan *epoch*, sebagaimana ditampilkan pada Gambar 2 yang memvisualisasikan kurva *loss* dan akurasi pelatihan. Pada *epoch* pertama, model memulai proses optimasi dengan nilai *loss* sekitar 0,24 dan akurasi berada pada kisaran 93,9 persen. Nilai awal ini menunjukkan bahwa kombinasi CNN dan *Transformer* mampu mengenali karakteristik dasar sinyal elektrokardiogram meskipun bobot jaringan masih berada pada tahap inisialisasi. Arsitektur CNN berperan mengekstraksi fitur spasial dari sinyal satu dimensi seperti pola amplitudo, kontur gelombang P, kompleks QRS, dan gelombang T, sehingga memberikan representasi awal yang lebih terstruktur sebelum diproses lebih lanjut oleh modul *Transformer*. Ketika memasuki *epoch* kedua, model menunjukkan peningkatan performa yang signifikan dengan penurunan *loss* menjadi 0,16 dan peningkatan akurasi hingga sekitar 96 persen. Peningkatan ini mencerminkan bahwa model mulai mampu menyesuaikan bobot internalnya dengan lebih efektif dalam mengenali pola morfologi detak jantung yang kompleks, termasuk variasi antar kelas seperti *Supraventricular* dan *Fusion beats* yang secara visual sering menyerupai kelas *Normal*. Tren peningkatan ini terus berlanjut hingga *epoch* kelima ketika akurasi mencapai lebih dari 97 persen dengan penurunan *loss* menjadi sekitar 0,11. Hal tersebut menandakan bahwa model semakin mampu membangun representasi fitur yang kaya dan diskriminatif dari sinyal EKG, sehingga kesalahan prediksi terhadap label *ground truth* semakin berkurang.

Memasuki *epoch* keenam hingga *epoch* kedelapan, kurva *loss* menunjukkan penurunan yang lebih landai, menandakan bahwa proses pelatihan memasuki tahap penghalusan parameter atau *deep optimization phase*. Pada tahap ini, penyesuaian bobot yang dilakukan oleh *optimizer Adam* lebih bersifat memperbaiki detail mikro dari pola sinyal, terutama yang berkaitan dengan kelas minoritas yang cenderung sulit dikenali. Keberhasilan model dalam mencapai *loss* yang semakin kecil menunjukkan bahwa jarak antara prediksi dan label aktual semakin menyempit. Hal ini juga tampak pada kurva akurasi yang terus naik secara perlahan namun konsisten hingga mencapai nilai tertinggi pada *epoch* kesembilan dengan akurasi sekitar 97,6 persen dan nilai *loss* mencapai 0,0883 sebagai titik minimum. Pola grafik pada Gambar 2 menunjukkan bahwa penurunan *loss* yang terjadi bersifat stabil, tanpa fluktuasi besar yang biasanya mengindikasikan ketidakstabilan pelatihan. Sementara itu, kurva akurasi menunjukkan kecenderungan mendatar yang wajar pada *epoch* akhir, menandakan model telah mendekati batas kemampuan optimalnya terhadap data pelatihan. Konsistensi antara kedua kurva tersebut memperlihatkan bahwa proses pelatihan berlangsung tanpa indikasi *overfitting* pada fase awal. CNN berperan menangkap fitur lokal yang menjadi ciri khas aritmia seperti bentuk QRS abnormal, sedangkan *Transformer* mengelola dependensi temporal antar titik sinyal sehingga konteks urutan waktu tetap terjaga. Sinergi keduanya menghasilkan model yang tidak hanya mampu memahami bentuk gelombang secara lokal tetapi juga hubungan temporal secara global.

Selain itu, stabilitas proses pelatihan juga mengindikasikan bahwa konfigurasi hiperparameter yang digunakan, termasuk learning rate, ukuran batch, dan mekanisme optimisasi, telah dipilih secara tepat sehingga mampu mendukung konvergensi model secara efektif. Tidak ditemukannya lonjakan *loss* atau penurunan akurasi secara drastis selama proses pelatihan menunjukkan bahwa arsitektur *hybrid CNN-Transformer* memiliki kemampuan adaptasi yang baik terhadap karakteristik data EKG yang kompleks dan bervariasi. Kondisi ini penting karena menandakan bahwa model


tidak hanya belajar menghafal pola pada data pelatihan, tetapi juga membangun representasi fitur yang relatif stabil dan generalizable, yang menjadi fondasi penting sebelum dilakukan pengujian lebih lanjut pada data validasi dan data uji untuk menilai performa model secara lebih objektif.



Gambar 2. Kurva Akurasi dan Loss

Secara keseluruhan, karakteristik kurva akurasi dan *loss* pada Gambar 2 memberikan gambaran yang kuat bahwa arsitektur *hybrid CNN* dan *Transformer* mampu mempelajari pola EKG dengan efisien, stabil, dan progresif. Kinerja model yang mencapai akurasi tinggi serta *loss* yang rendah mencerminkan optimisasi parameter yang baik serta kemampuan representasi fitur yang kuat. Selain itu, respons model terhadap data pelatihan menunjukkan bahwa mekanisme *attention* pada *Transformer* dapat memperkaya informasi yang diekstraksi CNN sehingga jaringan memiliki kemampuan generalisasi yang solid terhadap variasi sinyal. Dengan demikian, hasil pelatihan pada Gambar 2 menegaskan bahwa model *hybrid CNN* dan *Transformer* memiliki potensi yang sangat baik untuk digunakan sebagai sistem deteksi aritmia, terutama ketika diintegrasikan lebih lanjut dalam platform berbasis web yang dirancang untuk memproses sinyal EKG secara real time.

3.3 Analisis Matriks Konfusi



Gambar 3. Confusion Matriks

Matriks konfusi pada Gambar 3 menampilkan matriks konfusi hasil klasifikasi model *hybrid CNN* dan *Transformer* pada dataset MIT-BIH. Matriks ini memetakan hubungan antara label aktual (*True Label*) dan label prediksi (*Predicted Label*) untuk kelima kelas: *Normal* (N), *Supraventricular* (S), *Ventricular* (V), *Fusion* (F), dan *Unknown* (Q). Untuk memberikan evaluasi kuantitatif yang lebih terperinci mengenai kinerja model pada setiap kelas, ringkasan nilai *precision*, *recall*, dan *F1-score* disajikan dalam Tabel 1.

Tabel 1. Performa Klasifikasi Model Hybrid CNN-Transformer pada Setiap Kelas Aritmia

Kelas Detak Jantung	Precision (%)	Recall (%)	F1-Score (%)	Support
Normal (N)	98,21	99,43	98,82	72.471
Supraventricular (S)	95,70	57,13	71,55	2.223
Ventricular (V)	96,44	93,73	95,07	5.788
Fusion (F)	81,60	78,16	79,84	641
Unknown (Q)	96,52	99,30	97,89	6.431
Rata-rata (Macro Avg)	93,69	85,55	88,63	87.554

Berdasarkan data pada Tabel 1, kelas N dan Q tampil sebagai kelas dengan performa paling dominan. Tingginya jumlah prediksi benar pada kelas N dan Q menghasilkan nilai *recall* masing-masing sebesar 99,43% dan 99,30%. Jumlah kesalahan pada kedua kelas ini relatif kecil dan tersebar tipis ke beberapa kelas lain, yang mengindikasikan bahwa pola sinyal pada kelas N dan Q memiliki karakteristik visual yang kuat dan konsisten sehingga mudah ditangkap oleh kombinasi *feature extractor* CNN dan mekanisme *self-attention* pada *Transformer*. Kekonsistenan pola morfologi gelombang EKG normal serta pola khas pada kelas Q membuat representasi fitur yang dihasilkan stabil sehingga kesalahan klasifikasi dapat diminimalkan.


Hasil yang positif juga ditunjukkan pada kelas V (*Ventricular*), yang merupakan kelas kritis secara klinis. Model mampu mencatatkan *recall* sebesar 93,73% dan *precision* 96,44%. Tingginya sensitivitas ini menunjukkan kemampuan model dalam mengenali pola *ventricular ectopic beat* yang memiliki distorsi morfologi jelas, seperti pelebaran kompleks QRS. Meskipun terdapat sedikit kesalahan prediksi (267 sampel V terdeteksi sebagai N), performa ini menegaskan bahwa arsitektur yang diusulkan cukup andal untuk mendeteksi kelainan ventrikel yang berpotensi fatal.

Berbeda dengan kelas mayoritas dan kelas V, kelas S (*Supraventricular*) memperlihatkan tantangan signifikan dalam proses klasifikasi. Dari total 2.223 sampel kelas S, model mencatatkan nilai *recall* sebesar 57,13%. Tingginya misprediksi ke kelas N (912 sampel) menandakan adanya kemiripan morfologi yang sangat besar antara pola *supraventricular premature beat* dengan detak jantung normal. Pola SVPB yang cenderung memiliki variasi amplitudo dan bentuk gelombang yang lebih halus membuat fitur yang diperoleh CNN tidak sepenuhnya mampu membedakan karakteristiknya dari kelas Normal, sehingga *Transformer* sebagai pengambil keputusan akhir cenderung bias ke kelas mayoritas.

Kelas F (*Fusion*) turut menunjukkan pola tantangan yang sebanding dengan nilai *F1-score* 79,84%. Meskipun model berhasil memprediksi sebagian besar sampel dengan benar, masih terdapat sejumlah misprediksi ke kelas N dan V. Hal ini dapat dipahami secara klinis mengingat *fusion beats* merupakan kombinasi antara detak normal dan *ventricular* yang menyebabkan karakteristik sinyal menjadi campuran dan tidak seragam. Ketidakstabilan pola ini membuat model kesulitan menetapkan fitur dominan, sehingga keputusan *attention* sering kali condong pada pola yang lebih mirip, terutama dengan kelas N dan V.

Secara keseluruhan, matriks konfusi dan Tabel 1 memperlihatkan bahwa model *hybrid CNN* dan *Transformer* memiliki kemampuan generalisasi yang kuat pada kelas mayoritas dengan pola sinyal yang stabil, namun performa menurun pada kelas minoritas yang memiliki morfologi lebih variatif. Ketidakseimbangan data pelatihan berdampak pada menurunnya sensitivitas model terhadap kelas S dan F. Hal ini membuka peluang perbaikan melalui strategi seperti *rebalancing*, *class-weighting*, augmentasi berbasis *warping* atau *jittering* yang lebih spesifik untuk kelas minoritas, serta penyesuaian *hyperparameter Transformer* agar lebih sensitif terhadap variasi temporal mikro pada sinyal EKG. Meskipun akurasi keseluruhan mencapai sekitar 98 persen, analisis per kelas menegaskan bahwa peningkatan tetap diperlukan untuk memperoleh performa yang lebih merata pada seluruh kelas aritmia, khususnya kelas minoritas yang memiliki signifikansi klinis tinggi dalam deteksi dini gangguan irama jantung.

3.4 Analisis Kurva ROC



Gambar 4. Receiver Operating Characteristic (ROC)

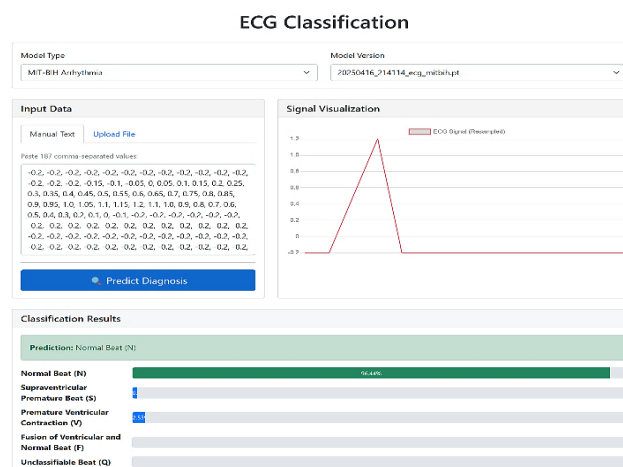
Kurva *Receiver Operating Characteristic* yang ditampilkan pada Gambar 4 memberikan gambaran menyeluruh mengenai kemampuan model *hybrid CNN* dan *Transformer* dalam membedakan berbagai pola detak jantung pada lima kelas aritmia, yaitu N, S, V, F, dan Q. Kurva yang berada sangat dekat dengan sudut kiri atas menunjukkan bahwa model memiliki tingkat sensitivitas tinggi disertai tingkat kesalahan positif yang rendah, yang merupakan ciri utama dari sistem klasifikasi yang kuat. Pada penelitian ini, nilai area under the curve untuk seluruh kelas menunjukkan performa yang sangat baik, yaitu 0,99 untuk kelas N, 0,96 untuk kelas S, 1,00 untuk kelas V, 0,99 untuk kelas F, dan 1,00 untuk kelas Q. Tingginya nilai AUC ini tidak hanya mencerminkan kemampuan model dalam memberikan

prediksi akurat secara keseluruhan, tetapi juga menunjukkan kestabilan keputusan model terhadap variasi sinyal EKG yang bersifat temporal dan non linier. Kurva ROC yang hampir menyentuh titik satu pada sumbu sensitivitas mengindikasikan bahwa jaringan berhasil belajar representasi fitur baik fitur spasial yang diekstraksi oleh CNN maupun fitur temporal dari modul *Transformer*. Keberhasilan model untuk mencapai AUC sempurna pada kelas V dan Q menunjukkan bahwa dua kategori ini memiliki karakteristik sinyal yang sangat dapat dibedakan dari kelas lainnya, sehingga sistem mampu mengoptimalkan proses klasifikasi tanpa banyak mengalami ambiguitas. Pada kelas V, pola *ventricular ectopic beat* yang memiliki durasi QRS lebih panjang dan morfologi kompleks lebih mudah ditangkap oleh lapisan konvolusi, sementara mekanisme *attention* pada *Transformer* memperkuat kemampuan pemisahan fitur dengan menganalisis hubungan antar titik sinyal. Demikian pula, kelas Q memiliki pola sinyal dengan ciri tertentu yang memudahkan pemisahan distribusi probabilitas sehingga menghasilkan nilai AUC sempurna.

Meskipun secara umum performa model sangat baik, kelas S menunjukkan AUC 0,96 yang masih lebih rendah dibanding empat kelas lainnya. Nilai ini menggambarkan bahwa meskipun model mampu membedakan mayoritas pola *supraventricular premature beat*, tetap terdapat beberapa kasus yang sulit dipisahkan secara sempurna dari kelas N atau V, terutama pada sampel yang memiliki bentuk gelombang mendekati pola normal atau mengalami penurunan kualitas sinyal. Kompleksitas fisiologis SVPB yang muncul dalam berbagai bentuk dan tingkat intensitas membuat model perlu bekerja lebih keras untuk mengidentifikasi fitur halus yang sering kali tertutupi *noise* atau artefak rekaman. Namun, meskipun terdapat tantangan tersebut, nilai AUC 0,96 tetap tergolong sangat baik dalam konteks klasifikasi multi kelas pada sinyal EKG karena menunjukkan bahwa sensitivitas model tetap tinggi dan kesalahan klasifikasi pada kelas ini relatif rendah dalam perhitungan keseluruhan. Secara menyeluruh, kurva ROC di Gambar 4 memperlihatkan kecenderungan yang konsisten bahwa arsitektur *hybrid CNN* dan *Transformer* mampu mempelajari representasi fitur dengan sangat efektif. Hubungan antara skor AUC yang tinggi dan distribusi kurva yang hampir sempurna pada seluruh kelas menandakan bahwa model bekerja secara optimal dalam menangani variasi sinyal, meminimalkan kesalahan prediksi, dan menjaga tingkat generalisasi yang kuat. Temuan ini mengonfirmasi bahwa model tidak hanya unggul dalam lingkungan pelatihan, tetapi juga memiliki potensi besar untuk diterapkan pada data dunia nyata dalam skenario deteksi aritmia otomatis. Dengan demikian, model yang dihasilkan dapat digunakan sebagai komponen kunci dalam sistem pendukung diagnosis berbasis web, menyediakan hasil klasifikasi cepat, akurat, dan stabil, sehingga bermanfaat dalam membantu tenaga medis melakukan evaluasi awal terhadap pasien maupun mendukung aplikasi pemantauan jantung secara mandiri.

3.5 Implementasi Platform Berbasis Web

Sebagai bukti konsep, model klasifikasi aritmia yang telah dilatih diimplementasikan ke dalam platform berbasis web yang dirancang untuk memfasilitasi proses analisis sinyal EKG secara praktis dan mudah digunakan. Antarmuka sistem pada Gambar 5 dirancang dengan menekankan aspek kemudahan navigasi, sehingga pengguna dapat memasukkan sinyal EKG melalui beberapa opsi *input*, yaitu memasukkan 187 titik data secara manual, mengunggah berkas CSV yang berisi deret numerik sinyal EKG, atau mengunggah berkas PDF yang kemudian diekstrak nilainya oleh sistem. Setelah data diproses, platform menghasilkan prediksi kelas aritmia secara *real-time* beserta distribusi probabilitas untuk setiap kelas dan visualisasi grafik sinyal yang telah dinormalisasi. Penyajian hasil ini tidak hanya memudahkan pengguna dalam memahami kondisi sinyal EKG, tetapi juga memberikan konteks visual terhadap detak jantung yang dianalisis. Kehadiran platform ini bertujuan memperluas aksesibilitas analisis EKG, baik untuk tujuan edukatif, penelitian, maupun eksplorasi mandiri, serta sejalan dengan studi implementasi skalabilitas yang menunjukkan bahwa penerapan arsitektur berbasis kontainer dengan mekanisme *Horizontal Pod Autoscaling* (HPA) mampu menurunkan waktu respons dan meminimalkan galat permintaan (*request error*) secara signifikan dibandingkan metode vertikal, meskipun dengan konsekuensi biaya komputasi yang perlu dikelola (Narendra et al., 2025).



Gambar 5. Tampilan Website



Antarmuka web dirancang dengan prinsip kesederhanaan dan responsivitas guna memastikan pengalaman pengguna yang intuitif. Hal ini krusial agar sistem dapat dioperasikan dengan mudah oleh pengguna non-teknis maupun tenaga medis di berbagai perangkat tanpa hambatan navigasi (Rangga Wahyu Pratama et al., 2025). Pengguna dapat memilih model yang akan digunakan, memasukkan sinyal EKG dalam format 187 titik data yang dipisahkan koma, dan kemudian menekan tombol *Predict* untuk mendapatkan hasil analisis secara langsung. Hasil prediksi ditampilkan dalam bentuk teks (kelas detak jantung yang terdeteksi) serta diagram batang distribusi probabilitas untuk masing-masing kelas: *Normal Beat* (N), *Supraventricular Premature Beat* (S), *Premature Ventricular Contraction* (V), *Fusion of Ventricular and Normal Beat* (F), dan *Unclassifiable Beat* (Q). Selain itu, sistem juga menyediakan visualisasi sinyal EKG yang diunggah dalam bentuk grafik linier, sehingga pengguna dapat memverifikasi pola sinyal secara visual. Desain visual ini membantu meningkatkan pemahaman pengguna terhadap kondisi detak jantung mereka dan mendukung edukasi mandiri mengenai pola EKG. Platform ini dikembangkan dengan pendekatan arsitektur modular yang memisahkan logika pemrosesan (*backend*) dan antarmuka pengguna (*frontend*). Desain modular ini dipilih untuk menjamin kemudahan pemeliharaan sistem serta mendukung skalabilitas integrasi fitur baru di masa mendatang, seperti penyimpanan histori detak jantung atau analisis tren pasien (Rangga Wahyu Pratama et al., 2025). Selain digunakan sebagai alat diagnosis mandiri, sistem ini juga memiliki potensi untuk dioptimalkan sebagai sarana pengumpulan data populasi secara anonim, yang dapat dianalisis lebih lanjut untuk mendukung riset epidemiologi dan pengambilan kebijakan kesehatan berbasis data. Dengan penerapan ini, penelitian tidak hanya menghasilkan model klasifikasi aritmia yang akurat, tetapi juga menghadirkan solusi digital yang inklusif, praktis, dan berkontribusi pada transformasi layanan kesehatan menuju ekosistem berbasis data.

3.6 Pembahasan Hasil

Berdasarkan hasil pengujian dan evaluasi yang telah dilakukan, model *hybrid CNN* dan *Transformer* menunjukkan performa yang sangat baik dalam mendeteksi lima jenis aritmia jantung secara otomatis. Peningkatan akurasi dan penurunan *loss* yang signifikan selama proses pelatihan (dari *epoch* pertama hingga *epoch* sembilan) menunjukkan bahwa arsitektur *hybrid* ini mampu belajar pola kompleks dari sinyal EKG secara efektif. Hasil matriks konfusi memperlihatkan bahwa model memiliki performa yang sangat tinggi pada kelas mayoritas, khususnya pada kelas *Normal* (N) dan *Unknown beats* (Q), dengan *F1-score* masing-masing mencapai 0,99 dan 0,98. Hal ini menunjukkan keandalan model dalam mendeteksi kondisi detak jantung yang paling sering muncul pada populasi umum.

Namun, performa pada kelas minoritas seperti *Supraventricular beats* (S) masih perlu ditingkatkan, terlihat dari nilai *recall* yang hanya mencapai 0,57. Hal ini dapat disebabkan oleh jumlah sampel yang lebih sedikit dan kemiripan morfologi sinyal dengan kelas *Normal*, yang menyebabkan model kesulitan membedakan pola. Masalah ketidakseimbangan kelas ini dapat diatasi dengan penggunaan teknik penyeimbangan dataset seperti *Synthetic Minority Oversampling Technique* (SMOTE). Berbeda dengan metode *over-sampling* konvensional yang hanya mereplikasi data, SMOTE bekerja dengan membangkitkan sampel sintetik di sepanjang segmen garis yang menghubungkan tetangga terdekat di ruang fitur, sehingga mampu memperluas wilayah keputusan kelas minoritas tanpa menyebabkan *overfitting* (Chawla, Bowyer, Hall, & Kegelmeyer, 2002). Studi terdahulu menunjukkan bahwa penerapan varian teknik ini, seperti *Borderline-SMOTE*, terbukti efektif meningkatkan performa identifikasi pada kelas minoritas tanpa mengubah karakteristik data asli secara signifikan (Zhou & Fang, 2024).

Kurva Receiver Operating Characteristic (ROC) menunjukkan nilai Area Under the Curve (AUC) yang sangat tinggi pada seluruh kelas, yaitu di atas 0,96, yang menegaskan kemampuan diskriminasi model dalam membedakan berbagai jenis aritmia. Nilai AUC yang tinggi menunjukkan bahwa model mampu mempertahankan true positive rate yang baik sekaligus menekan false positive rate pada berbagai ambang keputusan. Konsistensi AUC antar kelas juga mengindikasikan bahwa model memiliki robustness yang baik terhadap variasi sinyal EKG. Dengan karakteristik tersebut, kurva ROC mendukung potensi implementasi model *hybrid CNN* dan *Transformer* dalam aplikasi nyata untuk deteksi aritmia yang cepat dan akurat.

Implementasi awal dalam bentuk platform berbasis web juga memperlihatkan nilai praktis yang tinggi. Antarmuka yang sederhana dan intuitif memudahkan pengguna non-teknis dalam memahami hasil analisis sinyal EKG. Kehadiran fitur visualisasi sinyal serta distribusi probabilitas prediksi per kelas meningkatkan transparansi hasil dan memberikan pengalaman yang lebih informatif bagi pengguna.

Secara keseluruhan, model *hybrid CNN* dan *Transformer* berhasil meningkatkan performa deteksi aritmia secara signifikan. Temuan ini selaras dengan studi terbaru yang melaporkan bahwa arsitektur *hybrid CNN* dan *Transformer* mampu mencapai akurasi hingga 99,58% pada dataset MIT-BIH, mengungguli model berbasis CNN tunggal maupun *Transformer* tunggal dengan menggabungkan keunggulan ekstraksi fitur lokal dan pemodelan dependensi global (Kim et al., 2025). Sebagai perbandingan, penelitian terbaru yang menggunakan algoritma *Deep Neural Network* (DNN) standar hanya mencatatkan akurasi validasi sebesar 71,91% (Fajar & Nugraha, 2023). Hal ini membuktikan bahwa arsitektur *hybrid* yang diusulkan dalam penelitian ini, dengan capaian akurasi 98%, menawarkan peningkatan performa yang signifikan dibandingkan model *Deep Learning* konvensional maupun metode klasik seperti *K-Nearest Neighbour* (K-NN) (Fajar & Nugraha, 2023). Integrasi ke dalam ekosistem layanan kesehatan digital membuka peluang untuk mendukung deteksi dini aritmia di wilayah dengan keterbatasan fasilitas medis. Hal ini sejalan dengan temuan bahwa teknologi *Deep Learning* mampu memberikan efisiensi signifikan dalam analisis data kompleks untuk menghasilkan wawasan yang dapat ditindaklanjuti, sehingga secara efektif mendukung proses pengambilan keputusan klinis yang lebih cepat dan akurat (Insan et al., 2024).



4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi aritmia berbasis *web* yang mengintegrasikan model *hybrid* CNN dan *Transformer*, dengan capaian akurasi validasi 98% pada dataset MIT-BIH Arrhythmia. Integrasi kedua arsitektur ini terbukti efektif dalam mengekstraksi fitur spasial dan temporal secara simultan, menjadikan sistem ini sebagai alat bantu keputusan klinis yang potensial untuk mendukung diagnosis awal secara *real-time*. Meskipun demikian, evaluasi mendalam menunjukkan tantangan signifikan pada deteksi kelas *Supraventricular* (S) yang hanya mencatatkan sensitivitas 57,1% akibat kemiripan morfologi yang tinggi dengan detak normal. Selain itu, perlu dicatat secara eksplisit bahwa penelitian ini masih menggunakan skema pembagian data *intra-patient*, sehingga kemampuan generalisasi model terhadap data pasien yang benar-benar baru (*inter-patient*) belum sepenuhnya teruji dan menjadi batasan utama studi ini. Oleh karena itu, penelitian selanjutnya sangat disarankan untuk menerapkan protokol validasi lintas pasien yang lebih ketat serta mengeksplorasi teknik *preprocessing* canggih atau metode penyeimbangan data generatif seperti SMOTE guna meningkatkan sensitivitas pada kelas minoritas. Di sisi lain, mengingat tingginya kompleksitas komputasi model *hybrid*, strategi optimasi infrastruktur *cloud* yang adaptif maupun teknik efisiensi model seperti kuantisasi menjadi langkah krusial yang harus ditempuh agar sistem dapat diimplementasikan secara luas pada perangkat *wearable* dengan sumber daya terbatas, sehingga mendukung transformasi layanan kesehatan digital yang lebih inklusif dan akurat.

REFERENCES

- Alghieth, M. (2025). DeepECG-Net: a hybrid transformer-based deep learning model for real-time ECG anomaly detection. *Scientific Reports*, 15(1), 20714. <https://doi.org/10.1038/s41598-025-07781-1>
- Ansari, Y., Mourad, O., Qaraqe, K., & Serpedin, E. (2023). Deep learning for ECG Arrhythmia detection and classification: an overview of progress for period 2017–2023. *Frontiers in Physiology*, 14(September). <https://doi.org/10.3389/fphys.2023.1246746>
- Bai, X., Dong, X., Li, Y., Liu, R., & Zhang, H. (2024). A hybrid deep learning network for automatic diagnosis of cardiac arrhythmia based on 12-lead ECG. *Scientific Reports*, 14(1), 2441. <https://doi.org/10.1038/s41598-024-75531-w>
- Chandra, E., & Suwanto, D. (2021). Deteksi Dini untuk Mencegah Kematian Mendadak Akibat Aritmia. *Cermin Dunia Kedokteran*, 48(6), 303–306. <https://doi.org/10.55175/cdk.v48i6.1429>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, 16(2), 321–357. <https://doi.org/10.1613/jair.953>
- Cheng, X., Yi, J., & Peng, G. (2025). Cardiac Classification with Multi-Scale Convolutional Neural Network From Paper ECG. *MedRxiv*, 1–7. <https://doi.org/10.1101/2025.10.05.25337357>
- Fajar, M., & Nugraha, Z. (2023). Deteksi Aritmia Menggunakan Algoritma Deep Neural Network (Dnn) Pada Sinyal Elektrokardiogram. *EProceedings ...*, 10(5), 4155–4158. Retrieved from <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/download/21141/20704>
- Hao, R., Xiang, Y., Du, J., He, Q., Hu, J., & Xu, T. (2025). A Hybrid CNN-Transformer Model for Heart Disease Prediction Using Life History Data. *ArXiv Preprint ArXiv:2503.02124*. <https://doi.org/10.48550/arXiv.2503.02124>
- Ikram, S., Ikram, A., Singh, H., Ali Awan, M. D., Naveed, S., la Torre Díez, I., ... Candelaria Chio Montero, T. (2025). Transformer-based ECG classification for early detection of cardiac arrhythmias. *Frontiers in Medicine*, 12(August), 1–17. <https://doi.org/10.3389/fmed.2025.1600855>
- Insan, Khotimah, K., Yudistira, F., & Ardiansyah, M. (2024). Efisiensi Deep learning untuk Analisis Data dan Pengambilan Keputusan. *Jurnal Insan Peduli Pendidikan (JIPENDIK)*, 2(2), 79–82. Retrieved from <https://ejournal.lppinpest.org/index.php/jipendik/article/view/146>
- Kim, D., Lee, K. R., Lim, D. S., Lee, K. H., Lee, J. S., Kim, D. Y., & Sohn, C. B. (2025). A novel hybrid CNN-transformer model for arrhythmia detection without R-peak identification using stockwell transform. *Scientific Reports*, 15(1), 1–11. <https://doi.org/10.1038/s41598-025-92582-9>
- Lamba, S., Kumar, S., & Diwakar, M. (2025). FADLEC: feature extraction and arrhythmia classification using deep learning from electrocardiograph signals. *Discover Artificial Intelligence*, 5(1), 82. <https://doi.org/10.1007/s44163-025-00290-0>
- Madan, P., Singh, V., Singh, D. P., Diwakar, M., Pant, B., & Kishor, A. (2022). A Hybrid Deep Learning Approach for ECG-Based Arrhythmia Classification. *Bioengineering*, 9(4), 1–26. <https://doi.org/10.3390/bioengineering9040152>
- Mienye, I. D., & Swart, T. G. (2024). A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications. *Information*, 15(12), 755. <https://doi.org/10.3390/info15120755>
- Narendra, D. P., Sakti Pramukantoro, E., & Amron, K. (2025). Studi Implementasi Skalabilitas Pada Sistem Inferensi Data Elektrokardiogram Berbasis Cloud. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 9(1). Retrieved from <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/14339>
- Putra, B. W., Isnanto, R. F. I., Sari, P., Saputra, A., Sanjaya, M. R., & Mukti, A. N. S. (2021). Klasifikasi aritmia pada sinyal EKG menggunakan deep neural network. *JUPITER: Jurnal Penelitian Ilmu Dan Teknologi Komputer*, 13(1), 29–38. Retrieved from <https://jurnal.polsri.ac.id/index.php/jupiter/article/view/3245>



- Rangga Wahyu Pratama, Paskah Abadi Simanullang, Peter Tymoty Hutabarat, Revidamurti Daulay, & Adidtya Perdana. (2025). Rancang Bangun Website Pengelolaan Buku Digital Berbasis Natural Language Processing (Nlp). *Jurnal Teknologi Informasi Dan Komputer*, 11(1), 102–113. <https://doi.org/10.36002/jutik.v11i1.3755>
- Ratna Lestari Budiani Buana, & Imroatul Hudati. (2022). Review: Analisis Fitur Deteksi Aritmia dan Metode Deep Learning untuk Wearable Devices. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 11(1), 61–69. <https://doi.org/10.22146/jnteti.v11i1.3381>
- Sibarani, R. I., Pasaribula, L. A., Maduwu, T. S. P., Panggabean, D. S., & Aisyah, S. (2025). A Sistem Elektrokardiogram Berbasis Kecerdasan Buatan Untuk Deteksi Dini Aritmia Menggunakan Algoritma Deep Learning. *Jurnal Sistem Informasi Dan Ilmu Komputer*, 9(1), 101–109. Retrieved from <https://jurnal.unprimdn.ac.id/index.php/jusikom/article/view/7329>
- Silva, G., Silva, P., Moreira, G., Freitas, V., Gertrudes, J., & Luz, E. (2025). A Systematic Review of ECG Arrhythmia Classification: Adherence to Standards, Fair Evaluation, and Embedded Feasibility, 1–32. Retrieved from <http://arxiv.org/abs/2503.07276>
- Wu, Z., & Guo, C. (2025). Deep learning and electrocardiography: systematic review of current techniques in cardiovascular disease diagnosis and management. *BioMedical Engineering Online*, 24(1), 23. <https://doi.org/10.1186/s12938-025-01349-w>
- Zhou, F., & Fang, D. (2024). Multimodal ECG heartbeat classification method based on a convolutional neural network embedded with FCA. *Scientific Reports*, 14(1), 1–10. <https://doi.org/10.1038/s41598-024-59311-0>