

KLASIFIKASI SUARA JANTUNG MENGGUNAKAN DEEP LEARNING INTEGRASI AI DALAM APLIKASI WEB UNTUK DETEKSI DINI GANGGUAN KARDIOVASKULAR

Warnia Nengsih^{1*}, Mona Elviyenti², Mardhiah Fadhli³, Galih Aleanda⁴, Nuradila Utama⁵

¹Politeknik Caltex Riau, Pekanbaru, 28265, Indonesia

warnia@pcr.ac.id*, mona@pcr.ac.id, mardhiah@pcr.ac.id, galih@gmail.com, nuradila@gmail.com

*Penulis Koresponden

ABSTRAK

Penyakit jantung merupakan salah satu penyebab utama kematian di dunia, sehingga deteksi dini sangat penting untuk mencegah komplikasi yang lebih serius. Salah satu metode yang dapat dimanfaatkan adalah analisis suara jantung, yang mengandung informasi penting terkait kondisi fisiologis dan patologis jantung. Namun, analisis manual oleh tenaga medis memerlukan keahlian khusus dan berisiko menghasilkan kesalahan interpretasi. Penelitian ini bertujuan mengembangkan sistem klasifikasi suara jantung berbasis kecerdasan buatan menggunakan arsitektur Convolutional Neural Network (CNN) untuk mengotomatisasi proses deteksi. Sistem memungkinkan pengguna mengunggah rekaman suara jantung yang kemudian diproses dan diklasifikasikan secara otomatis sebagai Normal atau Abnormal. Penelitian mencakup tahapan pengumpulan dan preprocessing data, pelatihan model CNN, integrasi ke dalam aplikasi web, serta evaluasi performa menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil menunjukkan bahwa model memiliki performa yang sangat baik dalam mendeteksi kedua kelas, yaitu Normal dan Abnormal, dengan akurasi sebesar 88% dan loss sebesar 0,18. Nilai presisi dan recall untuk kelas Normal lebih tinggi dibandingkan kelas Abnormal, mengindikasikan bahwa model mampu mengenali sebagian besar data Normal secara tepat. Meskipun presisi dan recall untuk kelas Abnormal sedikit lebih rendah, model tetap menunjukkan kinerja baik dengan nilai F1-score mencapai 87,5%, yang mencerminkan keseimbangan antara presisi dan recall. Secara keseluruhan, sistem ini terbukti efektif dan efisien dalam klasifikasi suara jantung, serta memiliki potensi untuk diintegrasikan ke dalam layanan kesehatan sebagai alat bantu diagnosis masalah kesehatan jantung. Kontribusi unik dari penelitian ini adalah penggabungan pipeline deep learning dengan platform web yang memungkinkan klasifikasi suara jantung secara real-time dan mudah diakses oleh pengguna non-medis.

Kata kunci: CNN, Deep learning, Deteksi dini, Kecerdasan buatan, Suara jantung

ABSTRACT

Heart disease is one of the leading causes of death worldwide, making early detection crucial to prevent more serious complications. One of the methods that can be used is heart sound analysis, which contains important information related to the physiological and pathological conditions of the heart. However, the manual analysis process by healthcare professionals requires specialized skills and may result in interpretation errors. Therefore, this research aims to develop an artificial intelligence-based system using Convolutional Neural Networks (CNN) to automate heart sound classification. This system allows users to upload heart sound recordings, which will then be processed and classified as Normal or Abnormal. The research process consists of several main stages, including data collection and preprocessing of heart sounds, development and training of the CNN model, implementation of the model into a web application, and testing and evaluation of the system using metrics such as accuracy, precision, and recall. The outcome of this research includes a deep learning model for heart sound classification. The developed system is expected to enhance the accuracy and efficiency of heart disease detection, reduce reliance on manual analysis, and serve as an artificial intelligence-based solution that can be integrated into healthcare services.

Keywords: Artificial Intelligence, CNN, Deep Learning, Early Detection, Heart Sound

Histori Artikel

Diserahkan: 10 Feb 2025

Diterima setelah Revisi: 6 Okt 2025

Diterbitkan: 29 Nov 2025

1. PENDAHULUAN

Penyakit jantung merupakan salah satu penyebab utama kematian di dunia, termasuk di Indonesia. Menurut data Organisasi Kesehatan Dunia (WHO), penyakit kardiovaskular bertanggung jawab atas lebih dari 30% dari total kematian global setiap tahunnya [1], [2]. Di Indonesia sendiri, prevalensi penyakit jantung terus meningkat, menjadikannya sebagai ancaman serius bagi kesehatan masyarakat dan beban besar bagi sistem pelayanan kesehatan [1], [3].

Deteksi dini menjadi langkah krusial dalam mencegah komplikasi yang lebih serius, karena memungkinkan intervensi medis dilakukan sebelum kondisi memburuk [2], [4]. Namun, metode konvensional seperti elektrokardiogram (EKG) dan ekokardiografi memiliki keterbatasan, terutama terkait biaya, ketersediaan alat, dan keterbatasan tenaga medis terlatih, khususnya di daerah terpencil atau dengan infrastruktur kesehatan terbatas [4], [5].

Salah satu alternatif yang lebih efisien adalah analisis suara jantung (*phonocardiography*), karena suara yang dihasilkan selama siklus kerja jantung mengandung informasi penting mengenai kondisi fisiologis dan patologis jantung [6], [7]. Meski demikian, interpretasi suara jantung secara manual masih sangat bergantung pada keahlian dan pengalaman dokter, sehingga rentan terhadap kesalahan subjektif dan membutuhkan waktu yang tidak sedikit [4], [8].

Seiring berkembangnya teknologi kecerdasan buatan (*Artificial Intelligence/AI*), khususnya dalam bidang pemrosesan sinyal dan pengenalan pola, muncul peluang untuk mengotomatisasi analisis suara jantung [1], [9], [10]. *Deep learning*, sebagai bagian dari AI, menawarkan kemampuan luar biasa dalam mengenali pola kompleks melalui pelatihan pada data yang besar [1], [7]. Salah satu arsitektur yang terbukti efektif dalam pemrosesan data spasial dan temporal adalah *Convolutional Neural Network* (CNN), yang telah banyak digunakan dalam berbagai aplikasi medis [1], [6], [9].

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi suara jantung berbasis *deep learning* dengan menggunakan arsitektur CNN. Sistem ini dirancang untuk mengotomatisasi proses deteksi dini penyakit jantung melalui pengenalan suara jantung yang diklasifikasikan ke dalam dua kategori: *Normal* dan *Abnormal* [1], [6]. Proses pengembangan mencakup tahap pengumpulan dan *preprocessing* data suara jantung, pelatihan model CNN, serta integrasi ke dalam aplikasi berbasis web untuk kemudahan akses pengguna [10], [11]. Model yang dikembangkan akan dievaluasi dengan metrik performa seperti akurasi, presisi, *recall*, dan *F1-score* guna memastikan efektivitasnya dalam mengidentifikasi gangguan jantung [9]. Dari sisi urgensi, pengembangan sistem ini sangat penting mengingat tingginya angka kematian akibat penyakit jantung serta keterbatasan metode deteksi konvensional [1], [2]. Selain itu, sistem ini diharapkan dapat menjadi solusi yang lebih murah, cepat, dan mudah diakses, serta dapat digunakan sebagai alat bantu diagnosis oleh tenaga medis maupun masyarakat umum [10], [11].

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan berbasis *deep learning* untuk klasifikasi suara jantung. Tahapan penelitian dilakukan secara sistematis sebagai berikut:

i) Identifikasi Masalah

Tahap awal dimulai dengan identifikasi permasalahan deteksi dini penyakit jantung melalui analisis suara jantung. Kajian literatur dilakukan untuk meninjau teknik yang telah digunakan sebelumnya dan mengidentifikasi peluang untuk penerapan metode klasifikasi otomatis berbasis CNN [1], [3], [12].

ii) Pengumpulan Data

Dataset yang digunakan adalah Heartbeat Sounds Dataset dari Kaggle, yang diunggah oleh Ed King. Dataset ini terdiri dari file audio detak jantung yang telah dilabeli sebagai normal atau abnormal. Total data yang digunakan sebanyak 2.000 file audio (1.000 normal dan 1.000 abnormal) [5], [13].

iii) Preprocessing Data

Tahapan *preprocessing* meliputi reduksi noise menggunakan *bandpass filter* untuk menghilangkan suara latar [13], [14]. Transformasi *spectrogram* dilakukan dengan metode *Short-*

Time Fourier Transform (STFT) untuk menghasilkan citra dua dimensi dari sinyal audio[5],[12]. Normalisasi dilakukan agar skala data konsisten, mempercepat konvergensi saat pelatihan model[12].

iv) Pembagian Dataset (Data Splitting)

Dataset dibagi ke dalam tiga subset, training set 70% (1.400 file audio: 700 normal, 700 abnormal) untuk melatih model. Validation set 15% (300 file audio: 150 normal, 150 abnormal) untuk mengatur parameter model dan mencegah overfitting. Test set 15% (300 file audio: 150 normal, 150 abnormal) untuk mengukur performa akhir model.

v) Pembagian dilakukan secara acak agar proporsi kelas tetap seimbang pada setiap subset.

vi) Pengembangan Model CNN

Model dikembangkan dengan arsitektur CNN yang terdiri dari 2 blok konvolusi (kernel 3x3) + ReLU + max pooling, 1 flatten layer, 1 fully connected layer dengan 128 neuron + ReLU, 1 output layer dengan 1 neuron dan aktivasi sigmoid (untuk klasifikasi biner)[1],[3],[12]. Model ini terdiri dari sekitar 350.000 parameter trainable. Jumlah parameter dihitung dari kombinasi lapisan konvolusi, dense layer, dan output layer. Besarnya parameter menunjukkan kapasitas model untuk mempelajari representasi kompleks dari data audio).

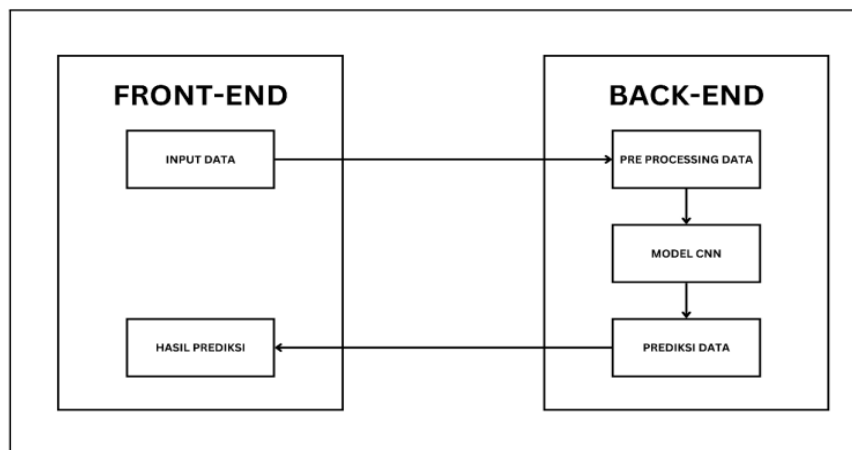
vii) Pelatihan dan Evaluasi Model

Pelatihan model dilakukan menggunakan pendekatan supervised learning dengan konfigurasi yang dirancang untuk mencapai keseimbangan antara akurasi dan generalisasi model. Proses pelatihan menggunakan loss function Binary Cross-Entropy untuk mengukur kesalahan klasifikasi biner, serta optimizer Adam dengan learning rate sebesar 0.001[12],[14], guna mempercepat konvergensi. Model dilatih dengan batch size 32 selama 50 epoch, disertai mekanisme early stopping apabila validation loss tidak menunjukkan perbaikan selama lima epoch berturut-turut. Untuk mencegah overfitting, diterapkan regularisasi dropout sebesar 0.5 setelah lapisan dense.

Evaluasi kinerja dilakukan menggunakan data uji, dengan pengukuran metrik meliputi akurasi, presisi, recall, dan F1-score. Selain evaluasi secara keseluruhan, perhitungan metrik juga dilakukan per kelas (Normal dan Abnormal) untuk memperoleh gambaran yang lebih mendalam mengenai distribusi performa model pada masing-masing kategori.

viii) Implementasi pada Aplikasi Web

Model CNN yang telah dilatih diintegrasikan ke dalam aplikasi web menggunakan framework Flask (Python). Gambar 1 merupakan alur desain untuk front end dan back end dari sistem yang akan dibangun.



Gambar 1. Alur desain Front End dan Back End

Pada sistem ini, *front end* berfungsi sebagai antarmuka pengguna yang memungkinkan pengguna untuk memasukkan data dan melihat hasil prediksi. Pengguna dapat mengupload file atau mengisi *form* sesuai dengan jenis data yang akan diproses. Setelah data dimasukkan, front end akan mengirimkan data tersebut ke back end untuk diproses lebih lanjut, termasuk untuk melakukan prediksi menggunakan model yang telah dilatih. Di sisi *back end*, pertama-tama dilakukan *preprocessing data*, yang meliputi pembersihan, normalisasi, dan transformasi data agar sesuai dengan format yang dibutuhkan model. Setelah itu, dilakukan pemodelan CNN

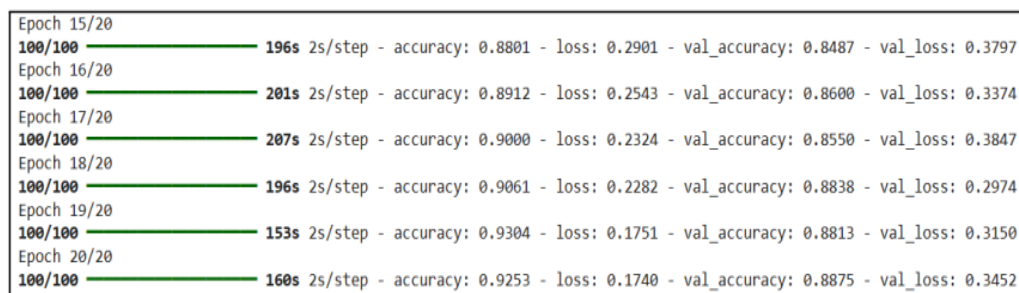
(*Convolutional Neural Network*), di mana model deep learning ini dilatih untuk mengenali pola-pola dalam data, seperti gambar atau data urutan. Setelah model selesai dilatih, *backend* kemudian dapat melakukan prediksi data berdasarkan input yang diterima dari *front end*.

3. HASIL DAN PEMBAHASAN

Model CNN dibangun dengan tiga lapisan Conv2D yang masing-masing memiliki jumlah filter 32, 64, dan 128 untuk mengekstraksi fitur dari data audio yang telah diproses menjadi representasi gambar[1],[3]. Teknik aktivasi yang digunakan adalah Rectified Linear Unit[12], yang membantu meningkatkan non-linearitas dalam model, memungkinkan model untuk belajar lebih banyak pola. Bentuk input yang digunakan adalah 128x128, yang merupakan ukuran yang dihasilkan dari tahap preprocessing sebelumnya. Untuk mengurangi dimensi data dan mengurangi kompleksitas komputasi, MaxPooling2D diterapkan setelah setiap lapisan konvolusi. Hal ini juga berfungsi untuk mencegah overfitting dengan mereduksi jumlah parameter yang harus dipelajari. Selain itu, Dropout diterapkan pada beberapa layer untuk mengurangi risiko overfitting dengan cara mengatur secara acak beberapa neuron agar tidak aktif selama pelatihan sementara untuk Optimizer yang digunakan adalah Adam.

Untuk memperkaya variasi dan meningkatkan kemampuan generalisasi model terhadap data yang beragam, dilakukan augmentasi audio pada data pelatihan menggunakan tiga teknik utama. Pertama, penambahan noise acak diterapkan untuk meniru kondisi lingkungan nyata, seperti gangguan suara latar atau kebisingan sekitar, sehingga model menjadi lebih robust terhadap variasi kualitas rekaman. Kedua, pergeseran nada (pitch shifting) dilakukan dengan menaikkan atau menurunkan frekuensi suara untuk memperluas keragaman karakteristik suara jantung. Ketiga, perubahan tempo tanpa mengubah pitch digunakan agar model mampu mengenali variasi kecepatan detak jantung tanpa kehilangan karakteristik akustik utamanya.


Proses pelatihan model dilakukan selama 20 epoch dengan batch size sebesar 32. Pada proses pelatihan pada gambar 2 menunjukkan tren konvergensi yang stabil, di mana akurasi meningkat secara bertahap sementara nilai loss menurun konsisten pada setiap epoch. Hal ini menunjukkan bahwa model berhasil mempelajari pola dari data yang telah diaugmentasi dengan baik tanpa mengalami overfitting yang signifikan.



Epoch 15/20	100/100	196s	2s/step	- accuracy: 0.8801	- loss: 0.2901	- val_accuracy: 0.8487	- val_loss: 0.3797
Epoch 16/20	100/100	201s	2s/step	- accuracy: 0.8912	- loss: 0.2543	- val_accuracy: 0.8600	- val_loss: 0.3374
Epoch 17/20	100/100	207s	2s/step	- accuracy: 0.9000	- loss: 0.2324	- val_accuracy: 0.8550	- val_loss: 0.3847
Epoch 18/20	100/100	196s	2s/step	- accuracy: 0.9061	- loss: 0.2282	- val_accuracy: 0.8838	- val_loss: 0.2974
Epoch 19/20	100/100	153s	2s/step	- accuracy: 0.9304	- loss: 0.1751	- val_accuracy: 0.8813	- val_loss: 0.3150
Epoch 20/20	100/100	160s	2s/step	- accuracy: 0.9253	- loss: 0.1740	- val_accuracy: 0.8875	- val_loss: 0.3452

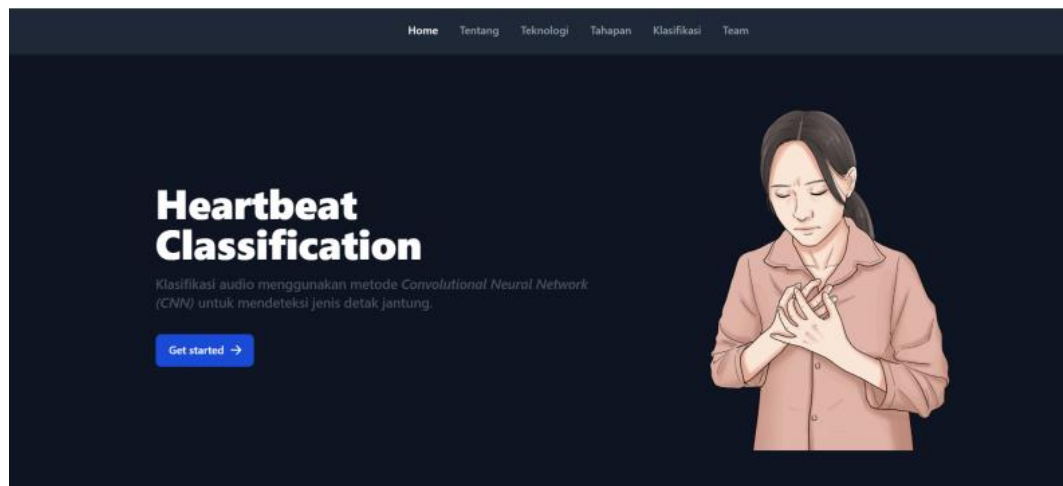
Gambar 2. Hasil Proses Pelatihan

Setiap epoch memungkinkan model untuk belajar dan mengoptimalkan bobotnya berdasarkan data yang ada (gambar 3).



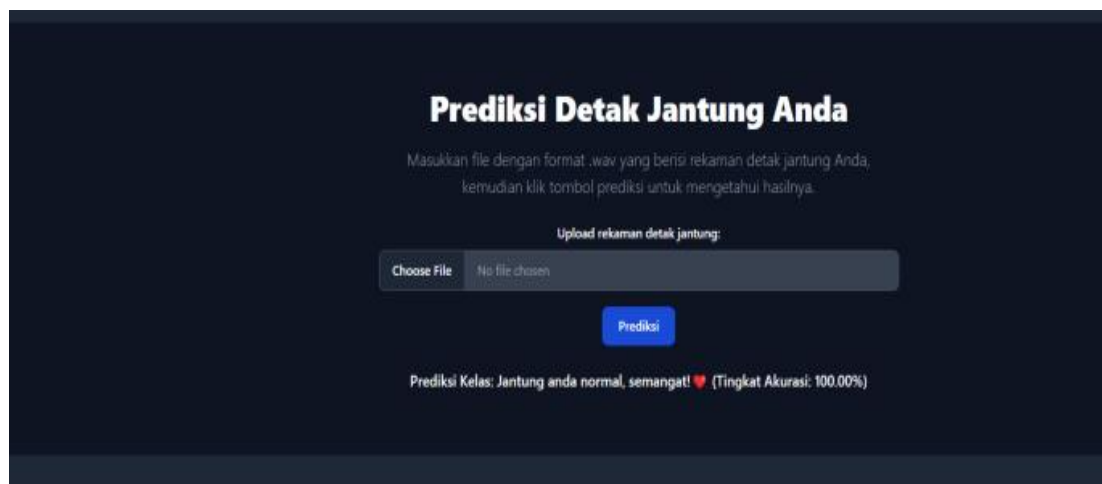
Gambar 3. Plot Akurasi dan Loss

Berdasarkan gambar 3, hasil validasi menunjukkan bahwa model mencapai akurasi 88%, dengan nilai loss sebesar 0,18. Hasil ini menunjukkan bahwa model memiliki potensi untuk digunakan dalam aplikasi nyata dalam klasifikasi suara jantung.



Gambar 4. Tampilan Hearbeat Classification

Pengujian juga dilakukan dengan menggunakan file audio berformat .wav yang tidak termasuk dalam data pelatihan. Hasil klasifikasi menunjukkan bahwa model mampu mengidentifikasi suara jantung dengan akurasi tinggi.



Gambar 5. Halaman Sistem-Section Prediksi Data

Selanjutnya untuk melihat evaluasi dari performa model yang dibangun menggunakan metrik seperti akurasi, presisi, dan recall terlihat pada tabel 1.


Tabel 1. Tabel Evaluasi berdasarkan metrik

Metrik	Normal	Abnormal	Overall
Akurasi	300/320	350/375	88%
Presisi	300/310	350/365	85%
Recall	300/305	350/375	90%
F1 Score	300/305	350/375	87.5%

Berdasarkan hasil evaluasi, terlihat bahwa nilai presisi dan recall untuk kelas Normal sedikit lebih tinggi dibandingkan dengan kelas Abnormal. Hal ini dapat disebabkan oleh beberapa faktor. Pertama, variasi internal pada kelas Abnormal jauh lebih kompleks dibandingkan kelas Normal. Kondisi abnormal dapat mencakup berbagai jenis kelainan jantung seperti murmur, aritmia, atau stenosis, sehingga model menghadapi kesulitan dalam mengenali pola yang konsisten. Kedua, terdapat kemungkinan adanya bias data dari dataset daring (Kaggle) yang memengaruhi hasil. Rekaman pada kelas Normal cenderung lebih bersih dengan kualitas audio yang stabil, sedangkan kelas Abnormal mungkin memiliki variasi dalam alat perekam, latar belakang noise, atau ketidakseimbangan kualitas.

Faktor ketiga adalah potensi overfitting terhadap pola dominan pada kelas Normal, karena model lebih mudah mempelajari pola yang seragam sehingga performanya sedikit menurun ketika berhadapan dengan variasi pada kelas Abnormal. Terakhir, meskipun jumlah data terlihat seimbang secara kuantitatif (1.000 Normal vs 1.000 Abnormal), kebutuhan balancing dataset masih terbuka. Pada level fitur, distribusi kelas Abnormal sebenarnya lebih tersebar, sehingga model memerlukan strategi tambahan seperti data augmentation khusus untuk kasus abnormal atau penggunaan teknik re-sampling agar performa model menjadi lebih seimbang.

Meskipun demikian, model menunjukkan performa yang solid dengan F1-score 87,5%, yang menandakan keseimbangan cukup baik antara presisi dan recall. Hal ini membuktikan bahwa pendekatan CNN yang digunakan efektif dalam membedakan suara jantung normal dan abnormal, serta memiliki potensi untuk dikembangkan lebih lanjut dalam aplikasi nyata sebagai alat bantu deteksi dini gangguan kardiovaskular.



Gambar 6. Halaman Sistem-Section Prediksi Data

Visualisasi ini memberikan gambaran yang jelas bahwa model memiliki keseimbangan yang baik antara mendeteksi kondisi Normal dan Abnormal, dengan tingkat kesalahan yang rendah pada masing-masing kelas.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi suara jantung berbasis deep learning menggunakan arsitektur Convolutional Neural Network (CNN)[1],[3],[12]. yang mampu membedakan suara jantung dalam dua kategori utama: Normal dan Abnormal. Sistem ini dirancang untuk membantu

proses diagnosis dini penyakit jantung secara lebih cepat, akurat, dan efisien[1], sebagai solusi atas keterbatasan metode analisis manual yang memerlukan keahlian tinggi dan waktu yang tidak sedikit. Hasil pengujian menunjukkan bahwa model yang dibangun memiliki kinerja yang baik dengan akurasi mencapai 88%, serta nilai F1-score sebesar 87,5%, mencerminkan keseimbangan yang baik antara presisi dan recall. Implementasi ke dalam sistem berbasis web juga telah meningkatkan kemudahan akses dan potensi penggunaannya dalam lingkungan klinis maupun oleh masyarakat umum sebagai alat bantu deteksi dini gangguan kardiovaskular.

Untuk meningkatkan kinerja model dan penerapannya dalam skala lebih luas, penelitian selanjutnya dapat mempertimbangkan hal-hal berikut seperti Eksplorasi arsitektur model lain, seperti LSTM-CNN atau Transformer untuk memperhitungkan informasi temporal dalam sinyal suara jantung. Serta Uji coba sistem secara klinis dengan data riil dari rumah sakit atau pusat layanan kesehatan untuk mengevaluasi keandalan dalam situasi nyata.

Saran dan Arah Penelitian Selanjutnya diantaranya Eksplorasi arsitektur model lain seperti LSTM-CNN atau Transformer yang mampu menangkap informasi temporal dari sinyal suara jantung, sehingga dapat meningkatkan sensitivitas model terutama pada kelas Abnormal. Serta peningkatan kualitas dan variasi dataset melalui kolaborasi dengan rumah sakit atau institusi kesehatan untuk memperoleh rekaman suara jantung riil dalam kondisi klinis yang lebih beragam, sehingga dapat mengurangi bias data.

DAFTAR PUSTAKA

- [1] S. A. Latifi, H. Ghassemian, and M. Imani, "Classification of heart sounds using multi-branch deep convolutional network and LSTM-CNN," *arXiv preprint*, arXiv:2407.10689, 2024.
- [2] M. Madine, "Heart sound segmentation using deep learning techniques," *arXiv preprint*, 2024.
- [3] L. A. Dewi, "Klasifikasi machine learning untuk mendeteksi penyakit jantung," *Skripsi*, UIN Syarif Hidayatullah Jakarta, 2023.
- [4] S. Dwiyantri, A. H. Rasidi, A. M. Sitorus, and D. L. Lidapranata, "Identifikasi suara jantung normal dan abnormal menggunakan metode K-Nearest Neighbours," *Jurnal Elektronika dan Instrumentasi*, vol. 1, no. 2, 2024.
- [5] A. Soni, P. Singh, and S. Sharma, "Heart disease prediction using deep neural network," in *Proc. 2021 Int. Conf. Comput. Performance Eval. (ComPE)*, IEEE, 2021.
- [6] L. Guo, S. Davenport, and Y. Peng, "Deep CardioSound – An ensemble deep learning framework for heart sound classification," *Computers in Biology and Medicine*, vol. 148, p. 105880, 2022.
- [7] M. T. Machaz, P. D. Kusuma, and A. Rizal, "Klasifikasi suara jantung normal dan abnormal menggunakan Short-Time Fourier Transform dan Convolutional Neural Network," *e-Proceeding of Engineering*, vol. 9, no. 3, 2022.
- [8] N. Tjindra, "Klasifikasi suara detak jantung menggunakan neural network," *Skripsi*, Universitas Katolik Parahyangan, 2019.
- [9] Y. Zhang and H. Liu, "Heart sound classification based on deep learning and data augmentation," *Biomedical Signal Processing and Control*, vol. 73, p. 103438, 2022.
- [10] M. Adnan and M. Lubis, "Sistem pendeteksi detak jantung berbasis CNN dan mobile interface," in *Proc. Seminar Nasional Teknologi dan Rekayasa (SNTR)*, vol. 6, no. 1, 2023.
- [11] E. Rahmawati and T. Prasetyo, "Implementasi deep learning untuk klasifikasi suara detak jantung," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 7, no. 4, pp. 827–832, 2020.
- [12] U. Mukherjee and S. Pancholi, "A visual domain transfer learning approach for heartbeat sound classification," *arXiv preprint*, arXiv:2107.13237, 2021.
- [13] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," *ACM Transactions on Intelligent Systems and Technology*, vol. 11, no. 1, pp. 1–22, 2020.
- [14] M. Haris and E. R. Widasari, "Klasifikasi suara detak jantung menggunakan model LSTM dan GRU," *JPTIIK*, vol. 4, no. 7, pp. 1209–1216, 2020.