

Klasifikasi Supraventrikular Arrhythmia Berdasarkan Sinyal EKG Menggunakan Convolutional Neural Network

Supraventrikular Arrhythmia Classification Based On ECG Signal With Convolutional Neural Network

1st Dito Noor Fauzi

Fakultas Teknik Elektro

Universitas Telkom

Bandung, Indonesia

ditosauruz@student.telkomun
iversity.ac.id

2nd R Yunendah Nur Fuadah

Fakultas Teknik Elektro

Universitas Telkom

Bandung, Indonesia

yunendah@telkomuniversity.
ac.id

3rd Irma Safitri

Fakultas Teknik Elektro

Universitas Telkom

Bandung, Indonesia

irmasaf@telkomuniversity.ac
.id

Abstrak —Penyakit kardiovaskular adalah gangguan pada jantung dan pembuluh darah yang menyebabkan angka kematian tinggi di seluruh dunia. Salah satu jenis penyakit kardiovaskular atau penyakit jantung yang paling umum adalah Supraventrikular Aritmia (SVA). Diagnosis dini Supraventrikular Aritmia (SVA) membantu untuk mendapatkan pengobatan yang tepat dan mencegah komplikasi dan kematian mendadak. Pemeriksaan penyakit kardiovaskular atau penyakit jantung dilakukan dengan menganalisis morfologi atau dinamika elektrokardiogram (EKG). Otomatisasi analisis EKG dilakukan dengan menggunakan pendekatan deep learning *Convolutional neural network* (CNN) termasuk otomatisasi klasifikasi SVA. Sistem klasifikasi pada penelitian ini menggunakan CNN dengan database aritmia supraventrikular MIT-BIH dan database ritme sinus normal MIT-BIH. Penelitian ini mengklasifikasikan sinyal EKG menjadi SVA dan normal sinus rhythm (NSR). Metode ini diproyeksikan menghasilkan kinerja akurasi yang lebih tinggi dalam mengklasifikasikan SVA dan NSR. Pada penelitian Tugas Akhir ini melakukan klasifikasi performansi sistem berdasarkan metode *Convolutional Neural Network* berdasarkan sinyal Elektrokardiogram untuk menghasilkan kinerja akurasi lebih tinggi dalam mengklasifikasikan SVA dan NSR. Performansi sistem tugas akhir ini mencapai nilai akurasi 99% sehingga sistem ini dapat diimplementasikan secara efektif.

Kata Kunci — *Supraventrikular Aritmia (SVA), Elektrokardiogram (EKG), Convolutional Neural Network (CNN), Normal Sinus Rhythm (NSR)*.

Abstract—Cardiovascular disease is a disorder of the heart and blood vessels that causes high mortality rates worldwide. One of the most common types of cardiovascular disease or heart disease is Supraventricular Arrhythmia (SVA). Early diagnosis of Supraventricular Arrhythmia (SVA) helps to get the right treatment and prevent complications and sudden death. Examination of cardiovascular disease or heart disease is done by analyzing the morphology or dynamics of the electrocardiogram (ECG). Automation of ECG analysis is carried out using a deep learning Convolutional neural network (CNN) approach including SVA classification automation. The classification system in this study uses CNN with the MIT-BIH supraventricular arrhythmia database and the MIT-BIH normal sinus rhythm database. This study classifies ECG signals into SVA and normal sinus rhythm (NSR). This method is projected to produce higher accuracy performance in classifying SVA and NSR. In this final project, the system performance classification is based on the Convolutional Neural Network method based on the Electrocardiogram signal to produce higher accuracy performance in classifying SVA and NSR. The performance of this final project

system reaches 99% accuracy value so that this system can be implemented effectively.

Keywords—*Supraventrikular Aritmia (SVA), Electrocardiogram (ECG), Convolutional Neural Network (CNN), Normal Sinus Rhythm (NSR).*

I. PENDAHULUAN

Penyakit kardiovaskular atau penyakit jantung adalah gangguan pada jantung dan pembuluh darah yang menyebabkan angka kematian tinggi di seluruh dunia. Data statistik tahun 2019 dari Organisasi Kesehatan Dunia (WHO) menyatakan, bahwa 17,9 juta orang atau 32% dari seluruh kematian global disebabkan oleh penyakit kardiovaskular atau penyakit jantung [1]. Salah satu jenis penyakit kardiovaskular atau penyakit jantung yang paling umum adalah Supraventrikular Aritmia (SVA) [2]. Supraventrikular Aritmia (SVA) menyebabkan risiko kematian kardiovaskular lebih tinggi dengan 34,7% tingkat kematian mendadak yang 20% lebih tinggi dibandingkan dengan orang tanpa Supraventrikular Aritmia (SVA) [3]. Diagnosis dini Supraventrikular Aritmia (SVA) membantu untuk mendapatkan pengobatan yang tepat dan mencegah komplikasi dan kematian mendadak [4]. Pemeriksaan penyakit kardiovaskular atau penyakit jantung dilakukan dengan menganalisis morfologi atau dinamika elektrokardiogram (EKG) [5]. Analisis manual EKG membutuhkan tenaga medis yang berpengalaman, lebih banyak waktu dan usaha yang lebih tinggi[7]. Oleh karena itu, penelitian tentang otomatisasi analisis EKG menggunakan pendekatan deep learning telah dilakukan dalam beberapa tahun terakhir [8], termasuk otomatisasi untuk

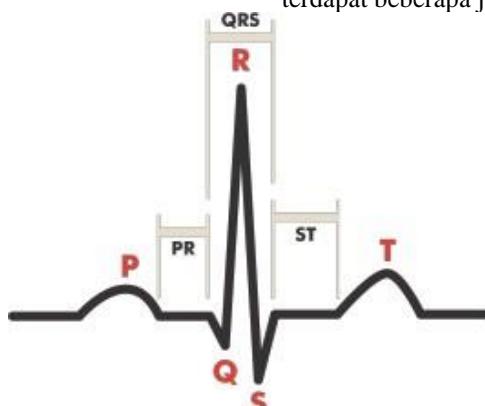
klasifikasi SVA menggunakan deep learning [9].

Proses klasifikasi otomatis memiliki beberapa tahapan penting, seperti preprocessing, ekstraksi ciri, dan klasifikasi. Hasil penelitian sebelumnya dengan menggunakan metode deep learning yang berbeda untuk klasifikasinya, seperti ANN, MLP, dan CNN. Berdasarkan klasifikasi tersebut metode CNN memiliki nilai terbaik. CNN secara otomatis mengekstrak fitur EKG yang membuat proses lebih efisien dan menghasilkan akurasi yang lebih tinggi. Namun, penelitian-penelitian sebelumnya belum menghasilkan nilai akurasi yang maksimal. Penelitian ini mengusulkan sistem klasifikasi menggunakan CNN dengan database aritmia supraventrikular MIT-BIH dan database ritme sinus normal MIT-BIH. Penelitian ini mengklasifikasikan sinyal EKG menjadi SVA dan normal sinus rhythm (NSR). Metode ini diproyeksikan menghasilkan kinerja akurasi yang lebih tinggi dalam mengklasifikasikan SVA dan NSR.

II. KAJIAN TEORI

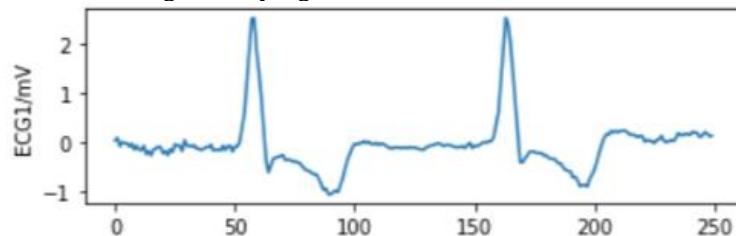
A. Elektrokardiogram (EKG)

Elektrokardiogram (EKG) adalah pengukuran perubahan sinyal listrik berdasarkan aktivitas jantung dan diplot sebagai grafik yang disebut elektrokardiogram [6]. Teknik EKG diterapkan dalam sebuah alat yang bernama elektrokardiograf. Alat ini digunakan dengan cara memasang elektroda (Ag/AgCl) di setiap tempat yang telah ditentukan, setelah itu alat tersebut membaca sinyal dari jantung. Sinyal yang dihasilkan oleh jantung melalui elektroda terdapat beberapa jenis, yaitu [10]:



GAMBAR 1
GELOMBANG PQRST PADA EKG.

1. Gelombang P, gelombang ini hasil dari kontraksi atrium yang dipicu oleh node SA.
2. Gelombang PR, terjadi penundaan pada node AV yang berguna dalam memberikan waktu kontraksi atrium dan transfer darah ke ventrikel sebelum ventrikel kontraksi.
3. Gelombang QRS, terjadi ketika ventrikel berkontraksi yang disebabkan rangsangan dari fiber Purkinje.
4. Segmen ST, segmen ini terjadi ketika terhubungnya isoelektrik dalam gerak potensial yang terdapat pada sel otot ventrikel kiri.
5. Gelombang T yang



GAMBAR 2
ABNORMALITAS SUPRAVENTRIKULAR ARITMIA.

C. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu dari golongan *supervised learning*. Pembuatan CNN termasuk melakukan pengenalan pola pada gambar atau audio yang sulit dipecahkan [11]. CNN memiliki keunggulan karena dapat belajar dari sejumlah kecil data dan ayunan sinyal kuat yang dihasilkan oleh banyak sumber. Dua komponen CNN adalah ekstraksi fitur dan klasifikasi [12]. Ketika sebuah convolutional layer bergabung dengan proses klasifikasi di bagian ekstraksi fitur, ia mulai mengidentifikasi [13].

1. Ekstraksi Fitur

Ekstraksi fitur adalah proses mengekstraksi sifat-sifat yang berbeda dari data yang akan diproses [14]. Tujuan ekstraksi fitur adalah untuk mengurangi jumlah data yang harus diproses,

merupakan proses terakhir dari gerak potensial pada sel otot ventrikel kiri.

B. Supraventrikular Aritmia (SVA)

Salah satu jenis penyakit jantung yang paling umum adalah Supraventrikular Aritmia (SVA) [2]. SVA adalah denyut jantung tidak teratur yang berasal dari atas ventrikel yang disebabkan oleh impuls listrik jantung yang tidak teratur. Menurut penelitian sebelumnya, SVA menyebabkan risiko kematian kardiovaskular lebih tinggi dengan 34,7% tingkat kematian mendadak yang 20% lebih tinggi dibandingkan dengan orang tanpa SVA [3]. SVA juga meningkatkan risiko kejadian kardiovaskular nonfatal seperti penyakit koroner, gagal jantung kongestif, dan vaskulopati perifer [3]. Diagnosis dini SVA membantu untuk mendapatkan pengobatan yang tepat dan mencegah komplikasi dan kematian mendadak [4].

mengambil informasi penting dari data yang harus diproses, dan meningkatkan presisi pemrosesan. Lapisan convolutional dan pooling adalah dua elemen dari ekstraksi fitur [15].

a. **Lapisan Konvolusi** : Blok bangunan utama CNN adalah lapisan konvolusi [14]. Lapisan konvolusi merupakan lapisan pertama yang akan mengolah citra sebagai model sistem masukan. Citra akan dikonvolusi dengan filter untuk mengekstrak fitur dari citra masukan yang disebut dengan peta fitur [13]. Ini merupakan persamaan 2.1.

$$h_i^l = f(b_i^{i,k} + \sum_{n=1}^N w_{n,1}^{l,k} \times x_{i+n-1}^{j-l,k})$$

Menurut persamaan h_i^l adalah keluaran dari i^{th} neuron di lapisan l ,

- $f()$ adalah fungsi aktivitas, $b_i^{l,k}$ adalah offset neuron berlapis-lapis l , $x_{i+n-1}^{i-1,k}$ adalah output dari neuron lapisan $i-1$, dan $w_{n,1}^{l,k}$ adalah kernel konvolusi k^{th} berlapis-lapis i^{th} [13].
- b. **ReLU** : Ketika gambar piksel memiliki nilai kurang dari nol, aktivasi Rel-U menetapkan semua nilai piksel ke nol. ReLU (Rectified Linear Unit) adalah lapisan aktivasi di CNN yang digunakan untuk meningkatkan tahap pelatihan pada jaringan saraf, yang dapat meminimalkan kesalahan[13].
 - c. **Pooling Layer** : Berdasarkan convolution layer, pooling layer merupakan proses sampling yang meminimalkan ukuran fitur [16]. Dengan memperkecil ukuran data keluaran convolution layer, overfitting dan jaringan yang kompleks berkurang [17]. Lapisan max-pooling hadir di setiap lapisan convolutional dalam percobaanini. Hasil pooling layer dapat dilihat pada persamaan 2.2 [18].

$$\sigma_i^{lk} = f(\sigma_i^{lk} \text{ pool}(x_i^{i-1,k} + b_i^{l,k})) \quad (2.2)$$

σ_i^{lk} adalah keluaran neuron h_i^{lk} berlapis-lapis l , $f()$ adalah aktivitas pada fungsi, $b_i^{l,k}$ adalah offset neuron di lapisan l , σ_i^{lk} adalah persamaan berat sampel, $x_i^{i-1,k}$ adalah output dari neuron di lapisan

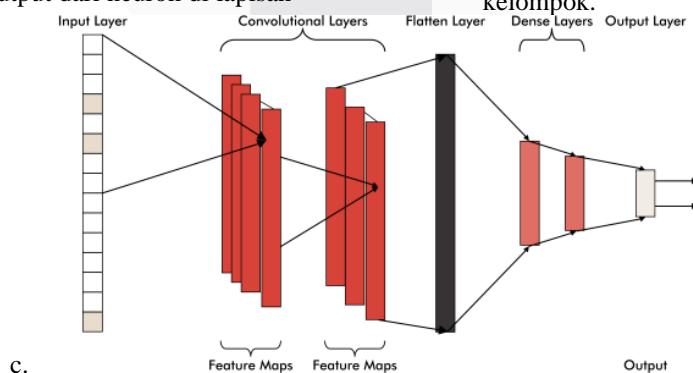
$i-1$, dan pool adalah fungsi dari pooling [18].

2. Lapisan Klasifikasi

Klasifikasi dan masalah klasifikasi berbobot yang melibatkan kelas yang saling eksklusif, lapisan klasifikasi menghitung kerugian lintas entropi. Lapisan menghitung jumlah kelas berdasarkan ukuran keluaran lapisan sebelumnya. Lapisan klasifikasi memiliki beberapa tahapan, diantaranya adalah flattening layer dan fully connected layer [19].

a. **Flattening Layer** : Metode ekstraksi fitur menghasilkan peta fitur dalam bentuk array multidimensi, yang harus diratakan sebelum digunakan sebagai input ke lapisan yang terhubung penuh. Dalam penelitian ini, layer flatten akan mengubah peta fitur menjadi vektor 1-D pada layer yang pada akhirnya terhubung [20].

b. **Lapisan Terhubung Sepenuhnya** : *Fully Connected Layer* adalah lapisan terakhir dari arsitektur multilayer perceptron. Semua neuron dari lapisan aktivasi sebelumnya akan terhubung di lapisan ini. Pada titik ini, semua neuron pada lapisan input harus diubah menjadi data satu dimensi [21]. Kemudian, sebagai varian lain dari pendekatan regresi logistik, aktivasi Sigmoid dapat digunakan untuk mengklasifikasikan lebih dari dua kelompok.

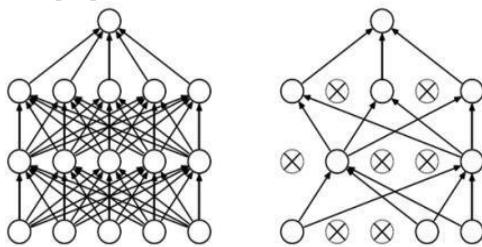


GAMBAR 3
ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK.

- d. **Dropout**: Fungsi dari dropout adalah teknik untuk mencegah masalah overfitting. Dropout ini

direpresentasikan pada *fully connected layer* dengan cara kerja menonaktifkan beberapa neuron

secara random yang tidak diperlukan. Gambar 4 menunjukkan ilustrasi dropout [22].



GAMBAR 4
ILUSTRASI PENGGUNAAN DROPOUT

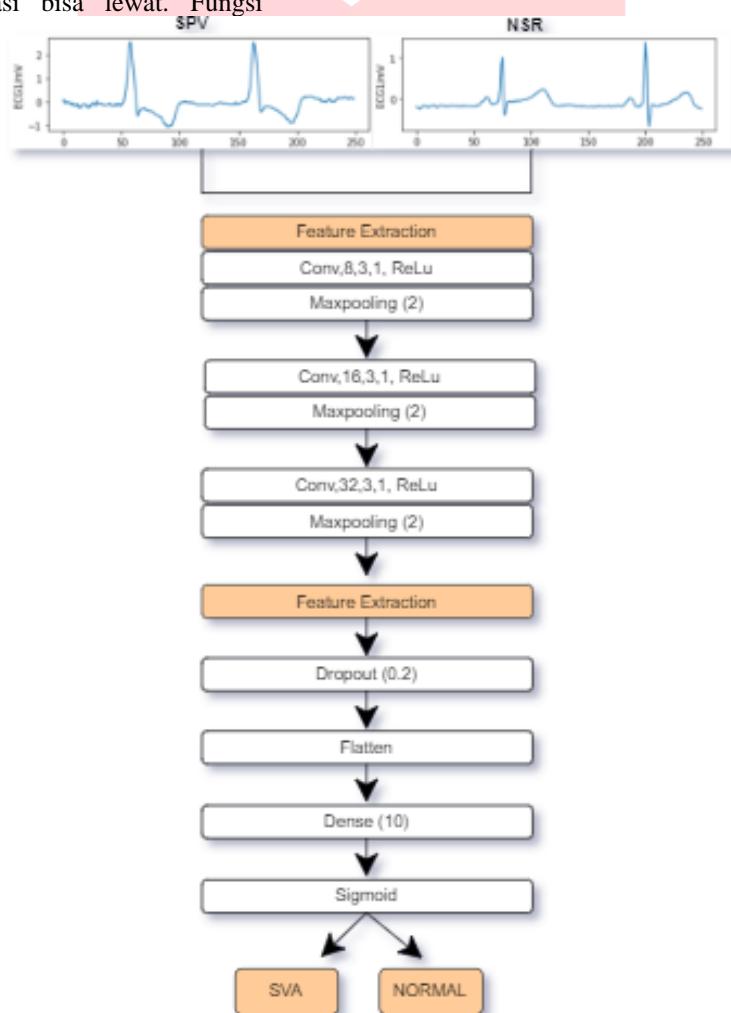
- e. **Sigmoid:** Fungsi aktivasi sigmoid digunakan untuk mengataseberapa banyak informasi bisa lewat. Fungsi

sigmoid menghasilkan output yang merupakan kisaran nilai antara 0 dan 1 . Persamaan dari fungsi sigmoid dapat dilihat pada persamaan berikut [23]:

$$\text{sigmoid}(x_i) = \left(\frac{1}{1+e^{-x_i}} \right)$$

III. METODE

Penelitian ini menggunakan data sinyal EKG dari dataset SVA MIT-BIH dan NSR MIT-BIH. Setiap kelas berisi file sinyal EKG untuk NSR dan SVA. Dataset menggunakan 90: 10 split. Dimana 90% data digunakan untuk pelatihan dan 10% untuk pengujian, sistem blok yang digunakan dalam penelitian ini dapat dilihat pada Gambar berikut.



GAMBAR 5
DIAGRAM ALUR SISTEM PELATIHAN.

Menurut diagram alur, Gambar. 5, dataset terdiri dari lapisan konvolusional dan lapisan *max-pooling*. Dalam penelitian ini,

model memiliki tiga lapisan konvolusional dan diikuti oleh lapisan max-pooling. Lapisan klasifikasi termasuk *dropout* yang

mencegah *overfitting* dengan memanfaatkan probabilitas 0,2 yang digunakan dalam penelitian ini. Flatten layer memadukan semua layer yang terlihat ke dalam layer backdrop untuk mengurangi ukuran file. *Dense layer* dan *sigmoid layer* diperlukan selain *dropout* dan *flatten*, dengan masing-masing lapisan padat memiliki jumlah neutron tertentu.

A. Kinerja Sistem

Kinerja sistem diperlukan untuk mengetahui akurasi sistem dalam mengklasifikasikan Aritmia Supraventrikular, dihitung dengan menggunakan persamaan matematis. Empat kinerja sistem yang digunakan: akurasi, presisi, *recall* dan *f1-score*.

$$\text{Akurasi} = \frac{\text{Tp} + \text{TN}}{\text{Tp} + \text{TN} + \text{FP} + \text{FN}}$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

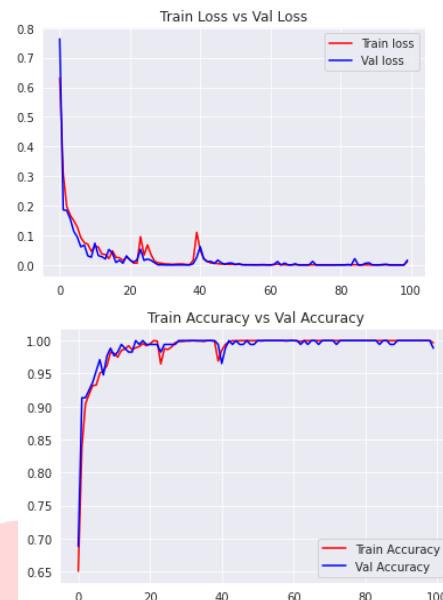
$$\text{Presisi} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

$$\text{F1-Score} = 2 \times \frac{\text{recall} \times \text{presisi}}{\text{recall} + \text{presisi}}$$

True Positive (TP) menunjukkan kondisi *Normal Sinus Rhythm* diklasifikasikan dengan benar sebagai *Normal Sinus Rhythm*. *True Negative (TN)* menunjukkan data diklasifikasikan dengan benar sebagai *Supraventrikular Arrhythmia*. *False Positif (FP)* adalah data *Supraventrikular Arrhythmia* yang salah diklasifikasikan sebagai *Normal Sinus Rhythm*. *False Negative (FN)* menunjukkan situasi di mana data *Normal Sinus Rhythm* tetapi salah diidentifikasi sebagai *Supraventrikular Arrhythmia*.

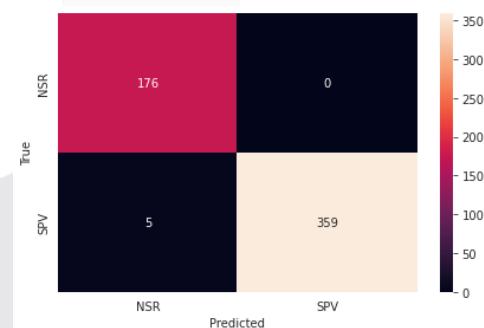
IV. HASIL DAN PEMBAHASAN

Pada penelitian ini akan membahas mengenai pengujian hasil dan analisis dari klasifikasi *Supraventrikular Arrhythmia* berdasarkan sinyal EKG menggunakan metode *convolutional neural network*. Pengujian berfokus pada jenis optimizer, nilai batch size, dan learning rate. Optimizer yang digunakan ada empat jenis, yaitu *Adam*, *Nadam*, *SGD*, dan *RMSprop*. Pengujian model pelatihan menggunakan empat nilai batch size mulai dari 8, 16, 32, dan 64. Learning rate pengujian ini menggunakan empat jenis, mulai dari 0.1, 0.01, 0.001, dan 0.0001. Berdasarkan hasil pengujian nilai terbaik terdapat pada *batch size* 64, *optimizer adam*, dan *learning rate* 0.01.



GAMBAR 6
CONFUSION MATRIX PADA MODEL PENGUJIAN.

Gambar 6 merupakan hasil pelatihan yang dilakukan dengan parameter yang disebutkan sebelumnya. Grafik pada gambar menampilkan bahwa hasil akurasi validasi adalah 100% dan *loss* validasi 0%. Hasil dengan akurasi terbaik ini terdapat pada *fold* 4 dari 5 dan *epoch* 99 dari 100.



GAMBAR 7
CONFUSION MATRIX PENGUJIAN TERHADAP LEARNING RATE.

TABEL 1. KINERJA SISTEM UNTUK PENGUJIAN TERHADAP LEARNING RATE

No.	Kelas	Presisi	Recall	F1-Score
1.	NSR	0.97	1.00	0.99
2.	SPV	1.00	0.99	0.99

Confusion matrix yang pada gambar 7 menampilkan bahwa hasil yang diberikan teridentifikasi cukup baik setiap kelasnya, namun terdapat 5 data SPV teridentifikasi sebagai data NSR. Tabel 1 menunjukkan hasil kinerja dari presisi kelas NSR dan SPV adalah 0.97 dan 1.00, *recall* NSR dan SPV

adalah 1.00 dan 0.99, dan *f1-score* NSR dan SPV adalah 0.99. Hasil yang diberikan tersebut menunjukkan bahwa model ini cukup menjanjikan. Oleh karena itu, ketika menggunakan model dengan *Adam optimizer*, *learning rate* 0.01, dan *batch size* 64 dapat disimpulkan bahwa hasil akurasi 99%, karena tidak terjadi *overfitting*.

V. KESIMPULAN

Klasifikasi *Supraventrikular Aritmia* (SVA) secara otomatis berdasarkan pemrosesan sinyal audio menggunakan model *Convolutional Neural Network* (CNN) dengan 3 *hidden layer* dan tiga lapisan pooling maksimum. Eksperimen memberikan hasil terbaik ketika model yang diusulkan mengklasifikasikan dataset EKG ke dalam *normal sinus rhythm* (NSR) dan *Supraventrikular Aritmia* (SVA) menggunakan *Adam Optimizer* dan *learning rate* 0,01. Hasil pengujian dengan model ini menunjukkan nilai akurasi validasi 100%, dan 0% *loss* validasi, dan nilai akurasi 99%.

REFERENSI

- [1] (2021) Cardiovascular diseases (cvds). [Online]. Available: <https://www.who.int>
- [2] L. Xue, Y.-C. Yang, Q. Zhao, Z.-H. Zhao, Q.-X. Zeng, T. Yang, Q. Luo, B.-Y. Liu, X.-P. Ma, Z.-H. Liu et al., "The spectrum and prevalence of arrhythmia in different clinical pulmonary hypertension groups in chinese population," Clinical Cardiology, 2022.
- [3] E. Verde, A. P. de Prado, J. M. Lopez-Gómez, B. Quiroga, M. Goicoechea, A. García-Prieto, E. Torres, J. Reque, and J. Luno, "Asymptomatic intradialytic supraventricular arrhythmias and adverse outcomes in patients on hemodialysis," Clinical Journal of the American Society of Nephrology, vol. 11, no. 12, pp. 2210–2217, 2016.
- [4] Y. N. Fuadah and K. M. Lim, "Optimal classification of atrial fibrillation and congestive heart failure using machine learning," Frontiers in Physiology, vol. 12, 2022. [Online]. Available: <https://www.frontiersin.org/article/10.3389/fphys.2021.761013>
- [5] S. M. Anwar, M. Gul, M. Majid, and M. Alnowami, "Arrhythmia classification of ecg signals using hybrid features," Computational and mathematical methods in medicine, vol. 2018, 2018.
- [6] (2019) Informedhealth.org [internet]. cologne, germany: Institute for quality and efficiency in health care (iqwig); 2006-. what is an electrocardiogram (ecg)? [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK536878/>
- [7] M. A. Serhani, H. T. El Kassabi, H. Ismail, and A. Nujum Navaz, "Ecg monitoring systems: Review, architecture, processes, and key challenges," Sensors, vol. 20, no. 6, 2020. [Online]. Available: <https://www.mdpi.com/1424-8220/20/6/1796>
- [8] W. Caesarendra, T. A. Hishamuddin, D. T. C. Lai, A. Husaini, L. Nurhasanah, A. Glowacz, and G. A. F. Alfarsi, "An embedded system using convolutional neural network model for online and realtime ecg signal classification and prediction," Diagnostics, vol. 12, no. 4, 2022. [Online]. Available: <https://www.mdpi.com/2075-4418/12/4/795>
- [9] D. Koppad, "Arrhythmia classification using deep learning: A review," WSEAS Transactions on Biology and Biomedicine, vol. 18, pp. 96–105, 2021.
- [10] Q. Xie, S. Tu, G. Wang, Y. Lian, and L. Xu, "Feature enrichment based convolutional neural network for heartbeat classification from electrocardiogram," IEEE Access, vol. 7, pp. 153 751–153 760, 2019.
- [11] N. A. J. Arifin, "Pengolahan citra pada sinyal ekg," Media Elektro, vol. 11, no. 1, p. 27–33, 2019.
- [12] L. Eren, T. Ince, and S. Kiranyaz, "A generic intelligent bearing fault diagnosis system using compact adaptive 1d cnn classifier," Journal of Signal Processing Systems, vol. 91, no. 2, pp. 179–189, 2019.
- [13] K. K. Patro, A. Jaya Prakash, M. Jayamanmadha Rao, and P. Rajesh Kumar, "An efficient optimized feature selection with machine learning approach for ecg biometric recognition," IETE Journal of Research, pp. 1–12, 2020.
- [14] Y. N. Fu'adah, S. Sa'idah, I. Wijayanto, N. Ibrahim, S. Rizal, and R. Magdalena,

- “Computer aided diagnosis for early detection of glaucoma using convolutional neural network (cnn),” in Proceedings of the 1st International Conference on Electronics, Biomedical Engineering, and Health Informatics. Springer, 2021, pp. 467–475.
- [15] W. Zhang, L. Yu, L. Ye, W. Zhuang, and F. Ma, “Ecg signal classification with deep learning for heart disease identification,” in 2018 International Conference on Big Data and Artificial Intelligence (BDAI). IEEE, 2018, pp. 47–51.
- [16] M. A. Pramudito, Y. N. Fu’adah, R. Magdalena, A. Rizal, and F. F. Taliningsih, “Ecg signal processing using 1-d convolutional neural network for congestive heart failure identification.”
- [17] A. Rizal, R. Hidayat, and H. A. Nugroho, “Determining lung sound characterization using hjorth descriptor,” in 2015 International conference on control, electronics, renewable energy and communications (ICCEREC). IEEE, 2015, pp. 54–57.
- [18] J. Huang, B. Chen, B. Yao, and W. He, “Ecg arrhythmia classification using stft-based spectrogram and convolutional neural network,” IEEE access, vol. 7, pp. 92 871–92 880, 2019.
- [19] J S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, and D. J. Inman, “1d convolutional neural networks and applications: A survey,” Mechanical systems and signal processing, vol. 151, p. 107398, 2021.
- [20] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, and D. J. Inman, “1d convolutional neural networks and applications: A survey,” Mechanical systems and signal processing, vol. 151, p. 107398, 2021.
- [21] S. Khan, H. Rahmani, S. A. A. Shah, and M. Bennamoun, “A guide to convolutional neural networks for computer vision,” Synthesis Lectures on Computer Vision, vol. 8, no. 1, pp. 1–207, 2018.
- [22] L. Qolbiyatul, “Apa itu Convolutional Neural Network?,” 2019. [Online]. Available: <https://medium.com/@16611110/apa-itu-convolutional-neuralnetwork-836f70b193a4>. [Accessed: 20-July-22].
- [23] Fausett, L. 1994. Fundamentals of Neural Networks : Architectures, Algorithms, and Applications, Prentice Hall, New Jersey.