



## Deteksi Arritmia pada Sinyal EKG dengan Deep Neural Network

Bayu Wijaya Putra\*, Rahmat Fadly Isnanto, Purwita Sari

*Universitas Sriwijaya, Inderalaya, Indonesia*  
*\*e-mail korespondensi: bayuwisata@gmail.com*

**Abstract.** Health practitioners need electrocardiogram (ECG) devices in supervising the heart health.. Where currently p enelitian presents abnormal classification of arritmia in ECG signals based on MIT-BIH dataset using deep neural *network*.. Before the classification process, good data preparation is required in order to get good accuracy results. The research method starts from data preparation, preprocessing of ECG beat signal, extraction feature and classification of ECG beat signal. The final result of the classification can be seen from the data validation. Validation results get excellent results reaching mencapai 99.62% and sensitivity reaches 98.92%.

**Keyword:** *ECG, Deep Neural Network, Classification*

**Abstrak.** Praktisi kesehatan membutuhkan perangkat Elektrokardiogram (EKG) dalam mengawasi kesehatan jantung. Dimana saat ini penelitian ini memaparkan klasifikasi abnormal terhadap arritmia pada sinyal EKG berdasarkan dataset MIT-BIH dengan menggunakan *deep neural network*. Sebelum proses klasifikasi, dibutuhkan persiapan data yang baik agar mendapatkan hasil akurasi yang baik. Metode penelitian dimulai dari persiapan data, preprocessing sinyal beat EKG, fitur ekstraksi dan klasifikasi sinyal beat EKG. Hasil akhir klasifikasi dapat dilihat dari validasi data. Hasil validasi mendapatkan hasil yang sangat baik mencapai 99.62% dan sensitivity mencapai 98.92%.

**Kata kunci:** EKG, Deep Neural Network, Klasifikasi

### PENDAHULUAN

Perkembangan penelitian dalam bidang kecerdasan buatan telah berkembang sangat pesat, terutama pada kebutuhan kesehatan jantung. Penyakit arritmia di jantung perlu pengawasan intens oleh praktisi yang ahli dalam bidang detak jantung. Pengukuran detak jantung menggunakan elektrokardiogram (EKG) yang telah banyak digunakan oleh praktisi kesehatan [1]. Terutama praktisi kesehatan jantung yang jumlahnya tidak bisa mencukupi terhadap jumlah pasien penderita penyakit jantung terutama gangguan arritmia. Berbagai macam penelitian dilakukan guna mencari solusi terbaik dalam membuat model pengetahuan berbasis *machine learning* [2]. Teknik *machine learning* berevolusi dari konsep kecerdasan buatan yang dapat digunakan dalam tugas-tugas komputasi di mana algoritme konvensional tidak memungkinkan untuk dilakukan [3].

Analisis terhadap sinyal EKG merupakan salah satu solusi yang dapat mendeteksi dan mengelompokkan sinyal dan bentuk gelombang yang berbeda. Sinyal EKG yang dianalisis memiliki morfologi sinyal beat dengan bentuk gelombang PQRST. Gelombang P, gelombang QRS, dan Gelombang T dalam status bentuknya normal. Ada juga kasus dimana sinyal EKG menjadi tidak berbentuk normal. Pada kasus tidak normal, bentuk sinyal EKG akan berubah bentuk gelombang biasanya gelombang T, yaitu pada jangkauan ST dan ketinggian ST dimana hal ini


menyebabkan sinyal menjadi tidak normal. Pendeteksian ketidaknormalan detak jantung ini membutuhkan banyak sampel dari sinyal EKG untuk menghasilkan model pengetahuan yang baik [2]. Beberapa sampel didapat paling diperlukan dalam proses fitur ekstraksi guna mengambil ciri dari penyakit jantung pada sinyal. Ekstraksi fitur pada sinyal berfokus pada sinyal yang telah diperpendek dalam *beat*, guna mendapatkan hasil yang terbaik dari penelitian.

Saat ini, muncul tantangan penelitian dalam mendeteksi ketidaknormalan sinyal EKG pada detak jantung. Penyakit yang diteliti yaitu aritmia. Aritmia terjadi karena gangguan irama detak jantung yang terkadang penderita tidak bisa mengetahui kapan itu akan terjadi. Aritmia yang diteliti saat ini memfokuskan penelitian pada sinyal EKG yang telah dikumpulkan guna mendeteksi abnormal sinyal. Pendekatan yang dilakukan menggunakan teknik klasifikasi dimana teknik ini telah dilakukan oleh [1], memberikan hasil yang sangat baik dalam mengelompokkan antara sinyal normal dan tidak normal.

Metode klasifikasi memiliki beberapa kelebihan yang biasanya telah digunakan pada banyak penelitian sebelumnya seperti pengenalan pola, *data mining*, *machine learning*. Beberapa metode yang digunakan seperti support vector machine (SVM) [4], artificial neural network (ANN) [1], convolutional neural network (CNN) [2], dan deep neural network (DNN) [5]. Beberapa penelitian, telah menggunakan metode DNN dan memberikan hasil yang baik pada bidang yang klasifikasi. Sehingga peneliti menggunakan metode deep neural network untuk mengklasifikasi abnormal aritmia.

## METODE PENELITIAN

Pada penelitian yang dilakukan dibagi menjadi 4 langkah (Gambar 1). Dimulai dari menyiapkan dataset sinyal EKG, memotong sinyal yang ukuran panjang menjadi sinyal *beat*, mengubah interval dari sinyal *beat*, mengekstraksi fitur sinyal *beat*, dan klasifikasi dengan metode DNN. Penelitian yang dilakukan menggunakan bahasa pemrograman Python.



**Gambar 1. Diagram Metode Penelitian**

## Dataset EKG


Dataset yang digunakan dari physionet.org, yang dikembangkan oleh MIT-BIH bersama BIH dalam bagian data Arrhythmia Database. Dataset tersebut berisi 48

rekaman elektrokardiogram pasien rekam jantung yang telah diseleksi dan telah didigitalisasi dengan resolusi 11-bit. Dengan demikian dataset ini sangat sesuai dengan penelitian yang dalam deteksi aritmia. Setiap record berisi berbagai bentuk gelombang. Lebih dari dua cardiologist telah membuat anotasi pada setiap record yang berkaitan dengan cara membaca sinyal.

### Segmentasi Sinyal

Pada awalnya dataset yang ada tidak menyediakan metode atau alat bantu dalam membaca data. Hanya memberikan anotasi dan referensi peneliti sebelumnya. Penggunaan dataset juga tergantung bagaimana penelitian akan dilakukan dengan membaca sinyal *beat*. Pada eksperimen awal, dataset yang berukuran 650.000 node, disegmentasi menjadi sinyal yang lebih pendek menjadi 252 node.


Pemotongan sinyal dimulai dari mengetahui jarak antara 2 puncak gelombang R-R pada sinyal original (Gambar 2) [6]. Hasilnya dapat menentukan gelombang QRS, kemudian dapat menentukan gelombang P dan T. Pada [7] sinyal *beat* diukur dari 0,25 detik sebelum puncak R disebut T1 dan setelah 0,45 detik dari puncak R berikutnya disebut T2 (Gambar 2).



Gambar 2. Segmentasi sinyal *beat*

### Normalisasi

Sinyal *beat* yang dihasilkan memiliki interval yang belum seragam, jika langsung melakukan klasifikasi akan menyebabkan komputasi yang berat. Perlu dilakukan normalisasi sinyal yang rentang diatas 1 menjadi diantara 0..1 (Gambar.3), sehingga berapapun banyaknya komputasi hasilnya akan tetap antara rentang yang dibawah 1. Hal ini berdampak pada konsumsi sumber daya perangkat dalam memproses fitur ekstraksi dan klasifikasi. Teknik normalisasi yang baik digunakan pada penelitian [5] dan [8], yaitu menggunakan *normalized bound*.



**Gambar 3. a) Sebelum Normalisasi -0,5..1 dan b) Setelah Normalisasi 0..1**

### Fitur Ekstraksi

Ciri khas dari sebuah sinyal beat dapat diekstrak menjadi kumpulan data yang kedepannya dapat digunakan dalam mengenali jenis sinyal. Pengambilan ciri khas sinyal dikenal dengan fitur ekstraksi. Penelitian [9] menjelaskan, fitur ekstraksi dapat mengambil ciri khas yang dapat menggambarkan karakteristik dari sinyal beat yang telah di normalisasi. Teknik fitur ekstraksi dijelaskan oleh [10] menggunakan autoencoder guna meningkatkan nilai akurasi hasil klasifikasi.

Arsitektur yang dikembangkan menggunakan 4 model evaluasi pada setiap eksperimen yang telah teliti. Panjang fitur dimulai dari 1,3,5,7 hidden layer. Input dan output layer memiliki 252 fitur atau setara dengan 1 panjang sinyal *beat*.

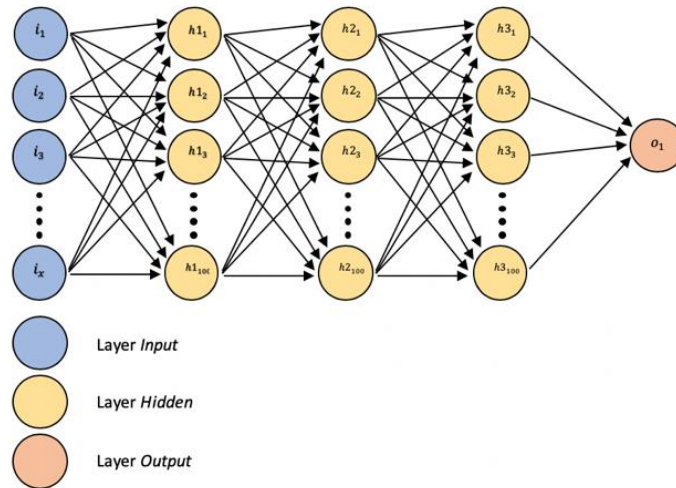
**Tabel 1. Model output fitur extraction dan input klasifikasi DNN**

Jumlah hidden Layer	Jumlah node pada layer	Fitur input DNN
1	[252, 126, 252]	126
3	[252, 126, 63, 126, 252]	63
5	[252, 126, 63, 32, 63, 126, 252]	32
7	[252, 126, 63, 32, 16, 32, 63, 126, 252]	16

### Proses Klasifikasi

Proses klasifikasi merupakan bagian utama dari penelitian ini. Proses klasifikasi menerapkan proses pengenalan sinyal normal dan tidak normal disebut Training Data. Proses uji coba hasil training data dengan dataset yang belum di training disebut Testing Data. Proses mengukur nilai besaran akurasi, dan ukuran lain terhadap hasil training dengan sisa dataset yang belum digunakan disebut Validasi Data. Analisis proses menggunakan bahasa pemrograman Python yang telah didukung dengan library yang dapat menghitung hasil validasi.

DNN merupakan bagian dari bagian Deep Learning dimana menggunakan algoritma Back Propagation dalam proses klasifikasi [8]. Pada autoencoder juga menggunakan DNN sehingga pada hasilnya dapat menjadi input bagi DNN pada klasifikasi .



Gambar 4. Arsitektur DNN

Pada input layer DNN klasifikasi dengan arsitektur dalam 4 model (Tabel 1). Bagian layer dalam satu kali percobaan meliputi bagian input, hidden layer dan output layer (Gambar 4). Anotasi  $x$  menjelaskan panjang fitur output dari hasil fitur ekstraksi. Layer input menjadi masukan awal sebanyak jumlah output dari fitur ekstraksi autoencoder. Layer hidden yang berada di tengah digunakan jumlah node yang sama dengan (Tabel 1) namun perbedaan jumlah hidden layer akan menentukan hasil akhir nilai validasi. Layer output hanya terdapat 1 node yang menggambarkan banyaknya kelas yang diklasifikasikan.

### HASIL DAN PEMBAHASAN

Pembagian jumlah dataset yang disajikan mulai dari *Training*, *Testing*, dan Validasi secara urutan, yaitu 72%, 18% dan 10%. Teknik *train test split* digunakan untuk memisahkan jumlah dataset. Selama proses training data menggunakan total 90% dataset yang dapat dilihat hasil yang baik (Tabel 2) pada setiap model. Model yang di-Training sebanyak 150 epoch dan batch size 48.

**Tabel 2. Hasil Training**

Hidden Layer	Rata-Rata Akurasi (%)	Rata-Rata Loss (%)
1	99,86	0,45
3	99,85	0,48
5	99,84	0,53
7		

**Tabel 2. Hasil Testing**

Hidden Layer	Rata-Rata Akurasi (%)	Rata-Rata Loss (%)
1	99,54	2,47
3	99,49	3,72
5	99,61	2,93

Untuk melihat hasil validasi perlu menggunakan analisis dalam mengukur hasil akurasi akhir training dan testing data. Model evaluasi yang dibuat menggunakan *Confusion Matrix* yang dihasilkan dari fitur testing data. Cara mengukur hasil performa didapat dengan menghitung nilai *False Negative* (FN), *False Positive* (FP), *True Negatif* (TN) dan *True Positive* (TP). Performa yang diukur, yaitu Akurasi (ACC), Sensitivitas (SEN), Spesifisitas (SPE), Presisi (PRE), Nilai F1 (F1), dan Error Rasio (E) [11].

**Tabel 3. Validasi Data**

Hidden Layer	ACC (%)	SEN (%)	SPE (%)	PRE (%)	F1 (%)	E (%)
1	99.59	98.50	98.50	98,91	98.70	0.41
3	99.59	98.10	99.10	99.35	98.72	0.41
5	99.62	98.92	98.92	98,64	98,78	0.38
7	98.54	97.93	97.93	99.17	98.54	0.46

Pada beberapa penelitian dengan bidang yang sama dengan DNN. Pada [4] menggunakan Neural Network dengan hasil 96,67%. Penelitian [2] menggunakan CNN, akurasi 98,18%. Pada [3] menggunakan kombinasi SVM dan neural network mendapat akurasi 92,4%. Hasil yang di teliti mendapatkan hasil akurasi mencapai 99,62%, Sensitivitas = 98,92%, Spesifisitas=98,92%, Presisi=98,64%, F1 Score=98,78 dan Error Rasio=0,38%.

Proses validasi menggunakan library dari python yang dapat mengkalkulasi dan membuat grafik model akurasi dan model loss (Gambar 5 dan 6). Hasil terbaik dari model 3, dengan 5 hidden layer. Hasil Confusion matriks yang disajikan adalah model terbaik pada 5 hidden layer, yaitu Training Data (Tabel 4), Testing Data (Tabel 5), dan Validasi Data (Tabel 6).

**Tabel 4. Confusion Matriks Training Data**


Kelas	Normal	Abnormal
Normal	13521	0
Abnormal	7	1251

**Tabel 5. Confusion Matriks Testing Data**

Kelas	Normal	Abnormal
Normal	3374	6
Abnormal	8	307

**Tabel 6. Confusion Matriks Validasi Data**

Kelas	Normal	Abnormal
Normal	1871	7
Abnormal	3	172



Gambar 5. a) Model Akurasi dan b) Model Loss

Panjang pendeknya fitur mempengaruhi hasil testing dan validasi. Pada bagian klasifikasi ditampilkan hasil grafik (Gambar 5) yang menggambarkan hasil akurasi dari training dan testing data. Adanya kecenderungan hasil test pada grafik yang disajikan mengikuti akurasi maupun loss dari training data sehingga hasil dari nilai training dan testing tidak terpaut jauh dan tetap baik hasilnya.

## KESIMPULAN

Proses yang terarah dalam setiap proses membutuhkan waktu yang tidak sedikit namun dapat memberikan hasil yang terbaik. DNN dapat mengenali sinyal *beat* aritmia baik itu sinyal normal dan abnormal berdasarkan dataset dari MIT-BIH. Pada setiap eksperimen yang dilakukan mulai dari 1,3,5,7 hidden dapat memberikan hasil yang berbeda yang akhirnya dapat memberikan kesimpulan yang baik. Hasil terbaik terdapat pada hidden layer 5, dengan akurasi mencapai 99,62%, dan Sensitivitas mencapai 98,92%.

## UCAPAN TERIMA KASIH

Terima kasih atas Hibah Penelitian Sateks Universitas Sriwijaya 2020 yang telah mendanai penelitian ini.

## DAFTAR RUJUKAN

- [1] G. B. Casanova, D. O. C. Sarmiento, M. J. I. Bustos, A. O. Duque, and H. A. Caicedo, "Techniques of Acquisition and Processing of Electrocardiographic Signals in the Detection of Cardiac Arrhythmias," *Respuestas*, vol. 24, no. 2, pp. 91–102, 2019.
- [2] J. Pestana, D. Belo, and H. Gamboa, "Detection of abnormalities in electrocardiogram (ECG) using deep learning," *BIO SIGNALS 2020 - 13th Int. Conf. Bio-Inspired Syst. Signal Process. Proceedings; Part 13th Int. Jt. Conf. Biomed. Eng. Syst. Technol. BIOSTEC 2020*, pp. 236–243, 2020.
- [3] G. Garcia, G. Moreira, D. Menotti, and E. Luz, "Inter-patient ECG heartbeat classification with temporal VCG optimized by PSO," *Sci. Rep.*, vol. 7, no. 1, pp. 1–11, 2017.
- [4] S. Sahoo, B. Kanungo, S. Behera, and S. Sabut, "Multiresolution wavelet transform based feature extraction and ECG classification to detect cardiac abnormalities,"



- Meas. J. Int. Meas. Confed.*, vol. 108, pp. 55–66, 2017.
- [5] B. W. Putra, M. Fachrurrozi, M. R. Sanjaya, A. Muliawati, A. N. S. Mukti, and S. Nurmaini, “Abnormality Heartbeat Classification of ECG Signal Using Deep Neural Network and Autoencoder,” in *2019 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2019, pp. 213–218.
- [6] A. W. Setiawan, R. A. Djohan, and F. I. Tawakal, “Deteksi Aritmia Menggunakan Sinyal EKG dengan Metoda Deteksi Puncak-R,” *Seniati*, vol. 5, pp. 123–128, 2019.
- [7] Q. Qin, J. Li, L. Zhang, Y. Yue, and C. Liu, “Combining Low-dimensional Wavelet Features and Support Vector Machine for Arrhythmia Beat Classification,” *Sci. Rep.*, vol. 7, no. 1, p. 6067, Dec. 2017.
- [8] S. Nurmaini, P. R. Umi, R. M. Naufal, and A. Gani, “Cardiac arrhythmias classification using Deep Neural Networks and principle component analysis algorithm,” *Int. J. Adv. Soft Comput. its Appl.*, 2018.
- [9] E. J. da S. Luz, W. R. Schwartz, G. Cámara-Chávez, and D. Menotti, “ECG-based heartbeat classification for arrhythmia detection: A survey,” *Comput. Methods Programs Biomed.*, vol. 127, pp. 144–164, Apr. 2016.
- [10] M. M. Al Rahhal, Y. Bazi, H. AlHichri, N. Alajlan, F. Melgani, and R. R. Yager, “Deep learning approach for active classification of electrocardiogram signals,” *Inf. Sci. (Ny)*, vol. 345, pp. 340–354, Jun. 2016.
- [11] F. M. Melgarejo-Meseguer *et al.*, “Electrocardiographic fragmented activity (II): A machine learning approach to detection,” *Appl. Sci.*, vol. 9, no. 17, 2019.