

Optimasi Deep Convolutional Neural Network (Deep CNN) untuk Deteksi Aritmia Melalui Sinyal EKG Menggunakan Arsitektur Conv1D

Yopi Julia Nurriski, Alamsyah*

Program Studi Teknik Informatika, FMIPA, Universitas Negeri Semarang, Indonesia
Gedung D5 Lt.2, Kampus Sekaran Gunungpati, Semarang 50229
E-mail: alamsyah@mail.unnes.ac.id

Diterima 6 November 2022

Disetujui 12 Februari 2023

Dipublikasikan 28 April 2023

Abstrak

Cardiovascular disease (CVD) adalah penyebab signifikan morbiditas dan mortalitas di seluruh dunia. Aritmia menjadi salah satu kondisi yang paling parah dari CVD. Penyakit ini mengacu pada ketidakteraturan denyut atau irama jantung. Penyakit aritmia dapat diidentifikasi melalui rekaman sinyal elektrokardiogram (EKG). Pada penelitian ini, dilakukan *data cleaning* yang bertujuan untuk menghilangkan missing value pada dataset. Adapun metode yang digunakan untuk klasifikasi adalah *Deep Convolutional Neural Network* (Deep CNN) dengan arsitektur Conv1D. Oleh karena itu, dilakukan perubahan dimensi input menjadi satu dimensi. Data hasil perubahan dimensi dilanjutkan dengan proses normalisasi data menggunakan metode standar (*z-score normalization*) dan pembobotan dengan menggunakan *WeightedRandomSample*. Hal ini dilakukan agar didapatkan keseimbangan data. Selanjutnya, dataset diekstraksi dan diklasifikasikan dengan Deep CNN. Pemilihan Deep CNN dalam ekstraksi fitur karena dapat mengekstraksi fitur yang sangat kompleks dari sinyal EKG sehingga dapat mencegah kehilangan informasi-informasi penting pada dataset. Selanjutnya dilakukan evaluasi menggunakan *Confusion Matrix*. Dari hasil evaluasi Deep CNN dengan arsitektur Conv1D pada deteksi aritmia menghasilkan akurasi 98,88% yang lebih tinggi dari metode sebelumnya.

Kata kunci: deteksi aritmia, sinyal EKG, *convolutional neural network*, *deep learning*, Conv1D

Abstract

Cardiovascular disease (CVD) is a leading cause of morbidity and mortality worldwide. Arrhythmia is one of the most severe CVD conditions. It refers to the irregularity of the heart rate or rhythm. Arrhythmia disease can be identified through recorded electrocardiogram (ECG) signals. In this study, data cleaning was carried out which aims to eliminate missing values in the dataset. The method used for classification is *Deep Convolutional Neural Network* (Deep CNN) with Conv1D architecture. Therefore, the input dimension is changed to one dimension. The data resulting from the dimensional change is followed by a data normalization process using the standard method (*z-score normalization*) and weighting using *Weighted Random Sample*. This is done to obtain data balance. Next, the dataset is extracted and classified with Deep CNN. Deep CNN was chosen for feature extraction because it can extract very complex features from ECG signals so as to prevent the loss of important information in the dataset. Furthermore, the evaluation is carried out using *Confusion Matrix*. From the evaluation results, Deep CNN with Conv1D architecture in arrhythmia detection produces an accuracy of 98.88% which is higher than the previous method.

Keywords: *arrhythmia detection*, *ECG signal*, *convolutional neural network*, *deep learning*, Conv1D

How to cite:

Nurriski Y. L., Alamsyah. (2023). Optimasi deep convolutional neural network (Deep CNN) untuk deteksi aritmia melalui sinyal EKG menggunakan arsitektur Conv1D. *Indonesian Journal of Mathematics and Natural Sciences*, 46(1), 10-20

PENDAHULUAN

Cardiovascular disease (CVD) adalah penyebab signifikan morbiditas dan mortalitas di seluruh dunia. Menurut Organisasi Kesehatan Dunia (WHO), lebih dari 17,3 juta kematian disebabkan oleh CVD pada tahun 2016, yang mewakili 31% dari seluruh kematian global dan diperkirakan akan meningkat menjadi 23,6 juta pada tahun 2030 (WHO 2021). CVD mencakup berbagai kondisi yang mempengaruhi jantung dan pembuluh darah, seperti penyakit jantung koroner, stroke, dan gagal jantung. Kondisi-kondisi ini sering dikaitkan dengan faktor risiko seperti tekanan darah tinggi, kolesterol tinggi, dan merokok. Diantara berbagai CVD, aritmia adalah salah satu kondisi yang paling parah, yang mengacu pada ketidakteraturan denyut atau irama jantung. Aritmia dapat menyebabkan konsekuensi serius seperti stroke, gagal jantung, dan kematian jantung mendadak. Oleh karena itu, deteksi dini dan diagnosis aritmia sangat penting untuk memberikan perawatan medis yang tepat dan mencegah hal yang merugikan (Rawal *et al.*, 2023).

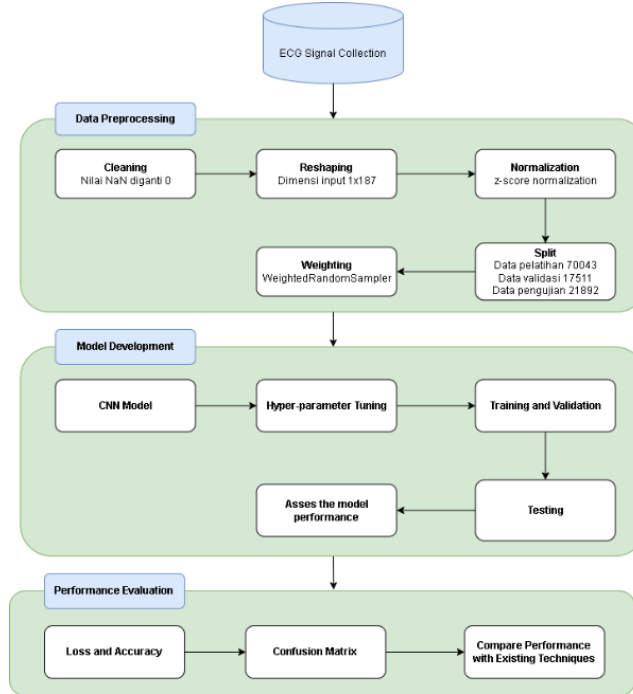
Elektrokardiogram (EKG) adalah tes non-invasif yang merekam sinyal listrik yang dihasilkan oleh jantung saat memompa darah ke seluruh tubuh (Agarwal *et al.*, 2016). EKG banyak digunakan untuk memantau jantung dan merupakan perangkat medis yang populer untuk memantau detak jantung karena kemudahan pengujian yang ditawarkannya (Midani *et al.*, 2023; Rawal *et al.*, 2023). Namun, menganalisis sinyal EKG membutuhkan keahlian dan sering kali tidak praktis, karena setiap detak jantung harus dianalisis. Selain itu, ada juga kemungkinan kesalahan manusia dalam analisis (Midani *et al.*, 2023; Choubey *et al.*, 2023). Oleh karena itu, diperlukan teknik komputasi otomatis untuk meningkatkan akurasi dan efisiensi deteksi aritmia (Midani *et al.*, 2023).

Kemajuan terbaru dalam elektronik dan infrastruktur transmisi data telah menghasilkan beberapa perangkat yang mampu memantau kesehatan manusia dengan bantuan sensor nirkabel. Perangkat-perangkat ini menawarkan potensi untuk memantau jantung secara terus menerus dan mendeteksi aritmia secara real-time (Pandey *et al.*, 2023). Menurut penelitian Sodmann *et al.* (2018) gerakan kardiovaskular berirama dapat digunakan untuk mendeteksi aritmia dengan menggunakan arsitektur jaringan saraf convolutional. Penelitian ini mencapai nilai F1-Score sebesar 82% setelah melakukan transformasi wavelet dinamis dan transformasi Fourier untuk resampling dan denoising pada tahap penyaringan. Dalam penelitian lain yang dilakukan oleh Hadjer *et al.* (2020), *multilayer perceptron* (MLP) digunakan untuk mendeteksi aritmia dari sinyal EKG. Mereka menggunakan array gerbang yang dapat diprogram untuk ekstraksi fitur dan kemudian menggunakan DWT untuk pengurangan fitur. Pendekatan ini mencapai akurasi klasifikasi sebesar 98,3%. Penelitian Kumar *et al.* (2023) mengusulkan sebuah teknik untuk mendeteksi detak jantung yang tidak normal menggunakan deep learning dan *fuzzy clustering* (Fuzz-ClustNet) (Handarko & Alamsyah, 2015). Mereka mengklasifikasikan sinyal EKG ke dalam 5 jenis penyakit jantung dan mencapai akurasi sebesar 98,66%. Meskipun hasil penelitian tersebut sudah cukup optimal tetapi penelitian lanjutan tetap diperlukan untuk meningkatkan nilai akurasi dan performa model dalam mendeteksi aritmia untuk diagnosis yang lebih akurat, mengidentifikasi aritmia yang jarang terjadi dan menghadapi variasi individu yang kompleks.

Pada penelitian ini menggunakan metode untuk mengklasifikasikan penyakit aritmia melalui sinyal EKG berbasis DNN dengan memanfaatkan arsitektur *Convolutional Neural Network* (CNN) (Oh *et al.*, 2018; Zheng *et al.*, 2020; Li *et al.*, 2018). CNN ini telah terbukti memiliki kemampuan yang baik dalam deteksi aritmia (Midani *et al.*, 2023; Rawal *et al.*, 2023; Choubey *et al.*, 2023). Metode dimulai dengan melakukan *preprocessing* dengan membuat *dictionary* untuk memetakan target, memploting 5 sinyal dalam label yang sesuai, mengubah dimensi data input menjadi 1 x 187 agar tepat diinputkan ke dalam model CNN (Liu *et al.*, 2021) dan merubah dimensi data output menjadi 1 x 5 agar sesuai dengan indeks target. Kemudian, data dilakukan normalisasi dan dihitung bobotnya untuk setiap kelas untuk melawan efek dari ketidakseimbangan kelas dan mendapatkan dataset yang lebih seimbang untuk pelatihan dan pengujian. Setelah itu, arsitektur CNN digunakan untuk ekstraksi fitur dan klasifikasi sinyal EKG ke dalam masing-masing kelas penyakit aritmia. Hasil klasifikasi kemudian dihitung *precision*, *recall*, dan F1-Score untuk setiap kelas menggunakan performance matrix (Prihanditya & Alamsyah, 2020). Diharapkan penelitian ini dapat meningkatkan akurasi deteksi aritmia sehingga dapat membantu dokter dalam mendiagnosis penyakit aritmia dengan akurat (Karri *et al.*, 2022).

METODE


Pada penelitian ini, deteksi penyakit aritmia melalui sinyal EKG menggunakan beberapa tahapan, yaitu preprocessing, ekstraksi fitur menggunakan deep CNN, klasifikasi menggunakan deep CNN dan klasifikasi, sebagaimana disajikan pada Gambar 1.



Gambar 1. Kerangka kerja dari deep CNN yang diusulkan untuk deteksi aritmia dari sinyal EKG

Deskripsi Dataset

Dataset yang digunakan pada penelitian ini berasal dari repositori Kaggle, yaitu MIT-BIH *Arrhythmia Dataset* di tautan berikut ini: <https://www.kaggle.com/shayanfazeli/heartbeat>. Penjelasan tentang *dataset* disajikan pada Gambar 2 dan Tabel 1.



Gambar 2. Visualisasi jenis detak jantung utama yang ada dalam *Dataset* Aritmia MIT-BIH

Tabel 1. Jenis detak jantung utama yang ada dalam *Dataset Aritmia MIT-BIH*

Kelompok	Deskripsi
<i>Normal beat</i>	<i>Normal beat, right bundle branch block beat, left bundle branch block beat, nodal (junctional) escape beat, Atrial escape beat</i>
<i>Supraventricular premature beat</i>	<i>Nodal (junctional) premature beat, atrial premature beat, supraventricular premature beat, aberrated atrial premature beat</i>
<i>Premature ventricular contraction</i>	<i>Premature ventricular contraction, Ventricular escape beat</i>
<i>Fusion beat</i>	<i>Fusion of ventricular and normal beat</i>
<i>Unclassifiable beat</i>	<i>Fusion of paced and normal beat, unclassifiable beat</i>

Dataset aritmia MIT-BIH (Moody & Mark, 2001) berisi 48 rekaman EKG selama setengah jam yang diambil dari 47 pasien pada tahun 1975 hingga 1979 di Rumah Sakit Beth Israel (BIH) Boston dalam bentuk *array* dengan file *.csv*. Data tersebut tersedia secara publik di kaggle dan terdiri dari lima kategori detak jantung, termasuk *Normal beat*, *Supraventricular premature beat*, *Premature ventricular contraction*, *Fusion beat*, dan *Unclassifiable beat*. Jenis-jenis detak jantung utama dan contoh sinyal yang termasuk dalam setiap kategori dapat dilihat pada Tabel 1 dan Gambar 2. Pada Tabel 2 terdapat jumlah *dataset* dalam setiap kelas. Terdapat ketidakseimbangan kelas pada *dataset* tersebut. *Arrhythmia MIT-BIH Dataset* memiliki 72.471 sampel detak jantung normal, sedangkan jumlah sampel untuk semua kelas lainnya adalah 15.083.

Tabel 2. Jumlah sampel yang termasuk dalam berbagai kelas dalam *dataset* yang berbeda

Kelompok	Data Pelatihan	Data Validasi
<i>Normal beat</i>	58.009	14.462
<i>Supraventricular premature beat</i>	1.764	459
<i>Premature ventricular contraction</i>	4.673	1.115
<i>Fusion beat</i>	505	136
<i>Unclassifiable beat</i>	5.092	1.339

Preprocessing

Preprocessing atau pra-pemrosesan adalah proses pembersihan data yang dapat mengganggu proses prediksi (Anagnostou *et al.*, 2021). Tujuan dari *preprocessing* adalah untuk memastikan bahwa data yang digunakan untuk analisis atau pemodelan memiliki kualitas yang baik dan siap untuk digunakan. Pada penelitian ini dilakukan *preprocessing* data yang meliputi *cleaning*, *reshaping*, *normalisasi*, *split* dan *weighting*. Sebelum dilakukan *data cleaning*, dilakukan proses untuk mempersiapkan target dari data yang akan digunakan dalam pelatihan model. Kolom terakhir pada *dataset* merepresentasikan label kategori dari 0 hingga 4, sehingga dapat digunakan sebagai target. Hal ini dapat dilakukan dengan pemilihan kolom terakhir dari *dataset* menggunakan fungsi *iloc[:, -1]* pada pandas *dataframe*.

Pada tahap *cleaning*, *dataset* sinyal EKG yang berbentuk *array* pada file *.csv* akan dianalisis untuk menemukan kolom dan baris *dataset* yang bernilai *NaN*. Kemudian, nilai kosong atau *NaN* tersebut diganti dengan angka 0 menggunakan fungsi *fillna(0)*. Setelah tahap *cleaning*, tipe data pada target diubah menjadi integer menggunakan fungsi *astype('int')*. Tujuan dari tahap ini adalah untuk memastikan bahwa target yang digunakan dalam pelatihan model merupakan data yang valid dan dapat diproses oleh model. Tipe data dari seluruh fitur (*features*) pada *dataset* juga dikonversi menjadi tipe data *float* menggunakan *method astype('float')*. Hal ini dilakukan karena pada umumnya, model *machine learning* membutuhkan *input* yang berupa bilangan *real (float)* untuk melakukan perhitungan dan pelatihan. Hasil dari proses ini dapat dilihat pada Gambar 2 yang menampilkan 5 *dataset* teratas hasil *cleaning*.

	0	1	2	3	4	5	6	7	8	9	...	177	178	179	180	181	182	183	184	185	186	
0	0.977941	0.926471	0.681373	0.245098	0.154412	0.191176	0.151961	0.085784	0.058824	0.049020	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
1	0.960114	0.863248	0.461538	0.196581	0.094017	0.125356	0.099715	0.088319	0.074074	0.082621	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
2	1.000000	0.659459	0.186486	0.070270	0.070270	0.059459	0.056757	0.043243	0.054054	0.045946	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
3	0.925414	0.665746	0.541436	0.276243	0.196133	0.077348	0.071823	0.060773	0.066298	0.058011	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
4	0.967136	1.000000	0.830986	0.586854	0.356808	0.248826	0.145540	0.089202	0.117371	0.150235	...	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0


5 rows x 187 columns

Gambar 2. *Dataset* hasil *cleaning* dan perubahan tipe data


Dictionary dengan nama *class_names* yang berisi pemetaan antara indeks target (0,1,2,3,4) dibuat dengan nama kelas yang sesuai ('N', 'S', 'V', 'F', 'Q'). Nama kelas merepresentasikan masing-masing penyakit aritmia, yaitu N (normal), S (*Supraventricular premature or ectopic beat*), V (*Ventricular premature beat*), F (*Fusion of ventricular and normal beat*), dan Q (*Unclassifiable beat*). *Dictionary* ini berguna untuk mempermudah interpretasi hasil *output* dari model, sehingga dapat langsung diketahui nama kelas apa yang diprediksi oleh model pada setiap indeks kelas. Hal ini juga dapat memudahkan dalam evaluasi performa model dengan melihat *confusion matrix* dan *classification report*.

Pada *dataset* sinyal EKG yang digunakan pada penelitian ini, dimensi *input* memiliki ukuran 187 dan dimensi *output* memiliki ukuran 5. Namun, dikarenakan model CNN yang dibuat menggunakan *layer Conv1D* maka model hanya dapat memproses data berdimensi 1. Oleh karena itu, data *input* perlu diubah ukurannya menjadi (*batch_size*, 1, 187) menggunakan *method reshape* (-1, 1, 187). Begitu juga pada data *output*, dikarena data *output* yang diinginkan adalah 5 kelas maka data *output* perlu diubah menjadi (*batch_size*, 5) menggunakan *method reshape* (-1, 1).

Tahapan *preprocessing* selanjutnya adalah normalisasi data *input*. Normalisasi dilakukan untuk mengubah nilai-nilai dalam data *input* menjadi skala yang sama. Normalisasi membantu menghilangkan bias yang mungkin ada pada data dan menghindari masalah dalam proses analisis data yang muncul ketika fitur-fitur yang berbeda skala diperlakukan sama, seperti model yang tidak stabil atau bobot yang tidak seimbang pada setiap fitur (Kiranyaz *et al.*, 2021). Normalisasi dilakukan menggunakan metode standar (*z-score normalization*), yang mengubah data *input* menjadi memiliki nilai mean 0 dan standar deviasi 1 setelah proses normalisasi. Dengan normalisasi data ini, model pembelajaran mesin yang dibangun akan lebih akurat dan dapat menghasilkan hasil prediksi yang lebih baik. Gambar 3 dan Gambar 4. menunjukkan visualisasi hasil *plotting* *dataset* sinyal EKG sebelum dan sesudah dinormalisasi.



Gambar 3. Gambar plotting sinyal EKG sebelum dinormalisasi



Gambar 4. Gambar plotting sinyal ECG setelah dinormalisasi

Pembagian *dataset* yang akan digunakan telah disesuaikan dengan *dataset* pada penelitian sebelumnya, yaitu data latih dan data uji telah dibedakan dalam dua file berbeda. Data latih dibagi lagi menjadi data latih dan data validasi menggunakan *scikit-learn* dengan perbandingan 80:20. Kemudian, ditampilkan frekuensi masing-masing kelas dalam set pelatihan. Hal ini berguna untuk memastikan bahwa set pelatihan memiliki distribusi kelas yang seimbang dan tidak terlalu terfokus pada satu kelas tertentu, yang dapat mempengaruhi kinerja model dalam memprediksi kelas yang kurang representatif. Tabel 3. menunjukkan frekuensi data latih dan data validasi pada setiap kelas.

Tabel 3. Frekuensi data latih dan data validasi pada setiap kelas

Kelas Data	Data Latih	Data Validasi
N	57.880	14.591
S	1.805	418
V	4.676	1.112
F	541	100
Q	5.141	1.290

Tahapan *preprocessing* selanjutnya adalah *weighting* (Tabel 4). Pada tahap ini setiap sampel dalam suatu dataset akan diberikan bobot atau nilai yang berbeda. Tujuannya adalah untuk menyeimbangkan distribusi kelas di dalam data training yang tidak merata (Pedregosa *et al.*, 2011). Hal ini dilakukan dengan menghitung jumlah data pada setiap kelas di dalam data training. Kemudian, jumlah masing-masing kelas dinormalisasi agar nilainya berada dalam rentang 0-1. Selanjutnya, bobot dihitung dengan membalik nilai distribusi kelas, sehingga kelas minor memiliki bobot yang lebih besar daripada kelas mayor. Terakhir, bobot dinormalisasi kembali sehingga jumlahnya menjadi 1. Dengan melakukan *weighting*, maka akan mencegah model untuk terlalu fokus pada kelas yang dominan saja. *Weighting* pada penelitian ini diaplikasikan pada *loss function* sehingga dapat meningkatkan performa model dalam memprediksi kelas minoritas dengan lebih baik (Ahmed *et al.*, 2023; Xie & Lin, 2023). Dataset yang telah dilakukan *preprocessing* kemudian diekstraksi dengan arsitektur CNN menggunakan hiperparameter seperti terdapat pada Tabel 5.

Tabel 4. Hasil *weighting* setiap kelas aritmia


Kelompok	Bobot (weight)
0 : 'N'	0,0061091
1 : 'S'	0,19589744
2 : 'V'	0,07561909
3 : 'F'	0,65359497
4 : 'Q'	0,0687794

Tabel 5. Hiperparameter untuk arsitektur CNN yang diusulkan

Layer name	Filters	Kernel size	Input shape	Output shape
<i>nin_block</i>	64	11	(1, 1, 187)	(1, 32, 177)
<i>MaxPool1d</i>		2	(1, 32, 177)	(1, 32, 88)
<i>nin_block</i>	64	5	(1, 32, 88)	(1, 64, 88)
<i>MaxPool1d</i>		2	(1, 64, 88)	(1, 64, 44)
<i>nin_block</i>	64	3	(1, 64, 44)	(1, 128, 44)
<i>MaxPool1d</i>		2	(1, 128, 44)	(1, 128, 22)
<i>nin_block</i>	256	3	(1, 128, 22)	(1, 256, 22)
<i>MaxPool1d</i>		2	(1, 256, 22)	(1, 256, 11)
<i>nin_block</i>	512	3	(1, 256, 11)	(1, 512, 11)
<i>AdaptiveAvgPool1d</i>			(1, 512, 11)	(1, 512, 1)
<i>Flatten</i>			(1, 512, 1)	(1, 512)
<i>Linear</i>			(1, 512)	(1, 256)
<i>ReLU</i>			(1, 256)	(1, 256)
<i>Dropout</i>			(1, 256)	(1, 256)
<i>Linear</i>			(1, 256)	(1, 5)

Arsitektur CNN yang digunakan dalam penelitian ini memiliki 5 blok *layer*, yang terdiri dari 4 blok *Convolutional Layer* dan 1 blok *Fully Connected Layer*. Model ini dimulai dengan lapisan *nin_block* yang mengambil data input dan menerapkan fungsi non-linier menggunakan konvolusi 1D dengan kernel size 11 dan stride 1, serta normalisasi batch dan aktivasi *ReLU*. Setelah itu, dilakukan *MaxPool1d* layer dengan kernel size 2 dan stride 2 untuk mengurangi dimensi spasial keluaran sebanyak setengahnya. Proses ini diulang beberapa kali dengan jumlah filter yang semakin meningkat dari 32 hingga 512 pada lapisan terakhir. Kemudian, *AdaptiveAvgPool1d* digunakan untuk melakukan penyatuan rata-rata global dan mengurangi keluaran menjadi vektor fitur berukuran tetap. Output dari *Flatten layer* kemudian dilewatkan melalui dua lapisan yang terhubung sepenuhnya (*nn.Linear*(512, 256) dan *nn.Linear*(256, 5)) dengan aktivasi *ReLU* di antaranya dan layer dropout dengan *probabilitas dropout* 0,5. Model ini dirancang untuk mengekstraksi fitur yang berguna dari data input dan memetakan fitur tersebut ke kelas keluaran akhir menggunakan lapisan yang terhubung sepenuhnya, dengan lapisan dropout digunakan untuk mencegah *overfitting*.

Klasifikasi sinyal EKG ini dilakukan dengan menggunakan hasil fitur-fitur yang telah diekstraksi sebelumnya. Sinyal EKG diklasifikasikan ke dalam 5 kelas, yaitu N (Normal), S (*Supraventricular premature or ectopic beat*), V (*Ventricular premature beat*), F (*Fusion of ventricular and normal beat*), dan Q (*Unclassifiable beat*). *Dataset* yang digunakan untuk penelitian ini sebelumnya sudah dibagi menjadi dua bagian, yaitu data latih dan data uji dengan perbandingan 80:20. Hal ini dilakukan untuk memastikan terdapat cukup banyak data yang tersedia untuk pelatihan dan pengujian, serta menghindari masalah seperti *overfitting* dan *underfitting*. Kemudian data latih dibagi lagi dengan perbandingan 80:20 untuk data latih dan data validasi. Data latih digunakan untuk melatih algoritma CNN. Setelah model dilatih, model kemudian digunakan untuk pengujian data uji. Dalam proses ini, model CNN memproses data uji sinyal EKG dan menghasilkan probabilitas kelas hasil akhir yang kemudian digunakan untuk memilih kelas yang paling mungkin sebagai hasil klasifikasi. Metrik evaluasi kemudian digunakan untuk mengevaluasi kinerja model CNN dalam mengklasifikasikan data sinyal EKG.



Gambar 5. Arsitektur CNN yang digunakan untuk mengekstrak fitur dari sinyal EKG

Tabel 6. Hiperparameter untuk CNN yang digunakan dalam model yang diusulkan

Hyperparameter	Value
<i>Batch size</i>	512
<i>Learning rate</i>	5e-4
<i>Learning rate decay</i>	0.5
<i>Number of epochs</i>	40
<i>Weight decay</i>	1e-5
<i>Dropout</i>	0.3

Confusion Matrix merupakan sebuah metode untuk mengevaluasi performa dari algoritma pembelajaran mesin dalam memprediksi data aktual. *Confusion Matrix* (Alamsyah and T Fadila 2021) terdiri dari *True Positives* (TP), *True Negatives* (TN), *False Positives* (FP), dan *False Negatives* (FN) (Prasetyo *et al.*, 2020) yang merepresentasikan jumlah prediksi yang benar pada kelas positif, jumlah prediksi yang salah pada kelas positif, jumlah prediksi yang benar pada kelas negatif, dan jumlah prediksi yang salah pada kelas negatif pada suatu dataset. *Confusion Matrix* yang digunakan untuk mengevaluasi performa model pada penelitian adalah sebagai berikut:

1. *Accuracy*:

Ketepatan pengklasifikasi dalam mengkategorikan titik data ke dalam kelasnya masing-masing dapat direpresentasikan oleh akurasi. Secara formal, akurasi didefinisikan sebagai rasio antara jumlah total sampel yang diklasifikasikan dengan benar dan jumlah total sampel. Dalam notasi matematis, akurasi dapat diwakili oleh Persamaan (1).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

2. *Precision*:

Precision yaitu ukuran ketepatan pengklasifikasi dalam memprediksi kelas positif. *Precision* dapat dihitung sebagai rasio antara jumlah sampel positif yang diklasifikasikan dengan benar dan total sampel yang diklasifikasikan sebagai positif. Secara matematis, *precision* dapat direpresentasikan dengan Persamaan (2).

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

3. *Recall*:

Recall mewakili proporsi sampel positif yang diklasifikasikan sebagai positif. Secara lebih formal, ini dapat direpresentasikan sebagai rasio positif aktual yang diklasifikasikan sebagai positif terhadap jumlah total sampel positif. Secara matematis, ini dapat diwakili oleh Persamaan (3).

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

4. *F1 Score*:

F1-Score mewakili keseimbangan antara *precision* dan *recall*. Secara lebih formal, ini dapat direpresentasikan sebagai rata-rata harmonis dari *precision* dan *recall*. Secara matematis, ini dapat diwakili oleh Persamaan (4)

$$F1\ Score = \frac{2 \times P\ precision \times Recall}{P\ precision + Recall} \quad (4)$$

Pada ilustrasi di atas tentang matrik evaluasi dalam konteks deteksi aritmia, *True Positive* (TP) mewakili sampel aritmia yang diklasifikasikan sebagai aritmia, *False Positive* (FP) mewakili sampel non-aritmia yang diklasifikasikan sebagai aritmia, *True Negative* (TN) mewakili sampel non-aritmia yang diklasifikasikan sebagai non-aritmia, sedangkan *False Negative* (FN) mewakili sampel aritmia yang diklasifikasikan sebagai sampel non-aritmia.

HASIL DAN PEMBAHASAN

Pada bagian ini model *Deep CNN* yang diusulkan dibandingkan dengan beberapa model dasar pada MIT-BIH *Arrhythmia Dataset*. Pembagian rasio data pelatihan dan data pengujian juga disamakan agar mendapatkan perbandingan yang adil. Pada Tabel 7, dapat dilihat bahwa model *Deep CNN* yang diusulkan mengungguli semua teknik dasar klasifikasi aritmia. Selain itu, model *Deep CNN* yang diusulkan juga mengungguli teknik kontemporer dalam klasifikasi aritmia yang ada. Pada Tabel 8. ditunjukkan hasil perbandingan model *Deep CNN* yang diusulkan dengan teknik kontemporer pada klasifikasi MIT-BIH *Arrhythmia Dataset*.

Tabel 7. Perbandingan evaluasi deep CNN dengan teknik dasar klasifikasi pada MIT-BIH *arrhythmia dataset*

Method	Accuracy (%)	Precision (%)	Recall (%)	F1 score (%)
Support Vector Machine	8,76	83,0	86,28	84,61
Gaussian Naive Bayes	74,09	70,95	79,44	74,95
K-Means	78,56	84,03	70,33	76,57
Random Forest	70,62	66,76	84,85	74,72
K Nearest Neighbors	78,92	79,52	78,22	78,86
Logistic Regression	75,73	69,21	91,08	78,65
Decision Trees	85,77	84,11	87,55	85,79
Purposed Deep CNN	98,88	98,88	98,88	98,88

Tabel 8. Hasil Perbandingan Model *Deep CNN* yang Diusulkan dengan Teknik Kontemporer pada MIT-BIH *Arrhythmia Dataset*

Methods	Accuracy (%)	Precision (%)	Recall (%)	F1 score (%)
Hadjer <i>et al.</i> (2020)	82,04	72,73	98,97	83,84
Acharya <i>et al.</i> (2017)	82,04	77,94	93,81	85,14
Iqbal <i>et al.</i> (2018)	82,52	80,51	87,96	84,07
Singh <i>et al.</i> (2019)	75,24	71,56	79,59	75,36
Bhagyalakshmi <i>et al.</i> (2021)	84,07	82,25	88,9	86,52
Wang <i>et al.</i> (2020)	86,89	84,35	91,51	87,78
Fuzz-ClustNet (Kumar <i>et al.</i> 2023)	98,66	98,92	93,88	96,34
Purposed Deep CNN	98,88	98,88	98,88	98,88

Dari hasil evaluasi tersebut, diketahui bahwa *Deep CNN* dengan menggunakan beberapa kombinasi normalisasi dan *weighting* yang diusulkan memiliki kinerja lebih baik dari teknik klasifikasi lainnya dengan nilai akurasi 98,88%. Hal ini menunjukkan bahwa pentingnya normalisasi dan *weighting* pada *dataset* sehingga didapatkan hasil yang lebih optimal.

SIMPULAN

Implementasi model *Deep* CNN dengan arsitektur *Conv1D* pada *Dataset* Aritmia MIT-BIH menghasilkan peningkatan akurasi dalam deteksi aritmia melalui sinyal EKG, seperti yang diamati dari hasil pengujian. Peningkatan akurasi deteksi aritmia dapat dilihat dari matriks konfusi yang menunjukkan *Precision* sebesar 98,8%, *Recall* sebesar 98,8%, *F1-Score* sebesar 98,8%, dan akurasi sebesar 98,8%. Hasil ini menunjukkan bahwa model *Deep* CNN dengan arsitektur *Conv1D* dapat secara efektif meningkatkan akurasi deteksi aritmia.

DAFTAR PUSTAKA

- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adam, M., Gertych, A., & Tan, R. S. (2017). A deep convolutional neural network model to classify heartbeats. *Computers in Biology and Medicine*, 89, 389-96. <https://www.sciencedirect.com/science/article/pii/S0010482517302810>.
- Agarwal, S., Krishnamoorthy, V., & S Pratiher, S. (2016). ECG signal analysis using wavelet coherence and s-transform for classification of cardiovascular diseases. *International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 2765-70.
- Ahmed, A. A., Ali, W., Abdullah, T. A. A., & Malebary, S. J. (2023). Classifying cardiac arrhythmia from ECG signal using 1D CNN deep learning model. *Mathematics*, 11(3), 562.
- Alamsyah, A., & Fadila, T. (2021). Increased accuracy of prediction hepatitis disease using the application of principal component analysis on a support vector machine. *Journal of Physics: Conference Series*, 1968 012016. <https://doi.org/10.1088/1742-6596/1968/1/012016>
- Anagnostou, E., Dimopoulou, P., Sklavos, S., Zouvelou, V., Zambelis, T. (2021). Identifying jitter outliers in single fiber electromyography: comparison of four methods. *Muscle & Nerve*, 63(2), 217-224. <https://doi.org/10.1002/mus.27093>
- Bhagyalakshmi, V., Pujeri, R. V., & Devanagavi, G. D. (2021). GB-SVNN: genetic BAT assisted support vector neural network for arrhythmia classification using ECG signals. *Journal of King Saud University - Computer and Information Sciences*, 33(1), 54-67. <https://doi.org/10.1016/j.jksuci.2018.02.005>.
- Choubey, D. K., Jha, C. K., Kumar, N., Kumari, N., & Soni, V. (2023). Detecting heart arrhythmias using deep learning algorithms. *Wiley Online Library*. <https://doi.org/10.1002/9781119905233.ch15>
- Handarko, J. L., & Alamsyah, A. (2015). Implementasi fuzzy decision tree untuk mendiagnosa penyakit hepatitis. *UNNES Journal of Mathematics*. 4(2), 157-164
- Hadjer, Z., Talha, M. K., Meddah, K. & Slimane, S. O. (2020). FPGA-based system for artificial neural network arrhythmia classification. *Neural Computing and Applications*, 32(8), 4105-20. <https://doi.org/10.1007/s00521-019-04081-4>.
- Iqbal, U., Wah, T. Y., Habib Ur Rehman, M., Mujtaba, G., Imran, M., & Shoaib, M. (2018). Deep deterministic learning for pattern recognition of different cardiac diseases through the internet of medical things. *Journal of Medical Systems*, 42(12), 252. <https://doi.org/10.1007/s10916-018-1107-2>.
- Karri, M., Annavarapu, C. S. R., & Pedapenki, K. K. (2022). A real-time cardiac arrhythmia classification using hybrid combination of delta modulation, 1D-CNN and blended LSTM. *Neural Processing Letters*, 55(2), 1499-1526. <https://doi.org/10.1007/s11063-022-10949-9>.
- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. (2021) 1D Convolutional neural networks and applications: a survey. *Mechanical Systems and Signal Processing*, 151, 107398. <https://doi.org/10.1016/j.ymssp.2020.107398>
- Kumar, S., Mallik, A., Kumar, A., Ser, J. D., & Yang, G. (2023). Fuzz-ClustNet: Coupled fuzzy clustering and deep neural networks for arrhythmia detection from ECG signals. *Computers in Biology and Medicine*, 153, 106511. <https://doi.org/10.1016/j.combiomed.2022.106511>.
- Li, J., Si, Y., Xu, T., & Jiang, S. (2018). Deep convolutional neural network based ECG classification system using information fusion and one-hot encoding techniques. *Mathematical Problems in Engineering*. ID 7354081. <https://doi.org/10.1155/2018/7354081>.
- Liu, X., Wang, H., Li, Z., & Qin, L. (2021). Deep learning in ECG diagnosis: a review. *Knowledge-Based Systems*, 227, 107187. <https://www.sciencedirect.com/science/article/pii/S0950705121004494>.
- Midani, W., Ouarda, W., & Ayed, M. B. (2023). DeepArr: an investigative tool for arrhythmia detection using a contextual deep neural network from electrocardiograms (ECG) Signals.

- Biomedical Signal Processing and Control*, 85, 104954. <https://www.sciencedirect.com/science/article/pii/S1746809423003877>.
- Moody, G.B., & Mark, R. G. (2001). The impact of the MIT-BIH arrhythmia database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3), 45-50.
- Oh, S.-L., Ng, E. Y. K., Tan, R. S., & Acharya, U. R. (2018). Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats. *Computers in Biology and Medicine*, 102, 278-87. <https://www.sciencedirect.com/science/article/pii/S0010482518301446>.
- Pandey, S. K., Shukla, A., Bhatia, S., Gadekallu, T. R., Kumar, A., Mashat, A., Shah, M. A., & Janghel, R. R. (2023). Detection of arrhythmia heartbeats from ECG signal using wavelet transform-based CNN model. *International Journal of Computational Intelligence Systems*, 16(1). <https://doi.org/10.1007/s44196-023-00256-z>.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: machine learning in python. *Journal of Machine Learning Research*, 12(1), 2825-30.
- Prasetyo, B., Alamsyah, Muslim, M. A., Subhan, & Baroroh, N. (2020). Artificial neural network model for bankruptcy prediction. *Journal of Physics: Conference Series*. 1567 032022. <https://doi.org/10.1088/1742-6596/1567/3/032022>
- Prihanditya, H. A., & Alamsyah. (2020). The implementation of Z-score normalization and boosting techniques to increase accuracy of C4.5 Algorithm in diagnosing chronic kidney disease. *Journal of Soft Computing Exploration*, 1(1), 63-69. <https://doi.org/10.52465/josce.v1i1.8>
- Rawal, V., Priyank Prajapati, P., & Darji, A. (2023). Hardware implementation of 1D-CNN architecture for ECG arrhythmia classification. *Biomedical Signal Processing and Control*, 85, 104865. <https://www.sciencedirect.com/science/article/pii/S1746809423002987>.
- Singh, R. S., Saini, B. S., & Sunkaria, R. K. (2019). Arrhythmia detection based on time-frequency features of heart rate variability and back-propagation neural network. *Iran Journal of Computer Science*, 2(4), 245-57. <https://doi.org/10.1007/s42044-019-00042-1>.
- Sodmann, P., Vollmer, M., Nath, N., & Kaderali, L. (2018). A Convolutional neural network for ECG annotation as the basis for classification of cardiac rhythms. *Physiological Measurement*, 39(10), 104005. <https://dx.doi.org/10.1088/1361-6579/aae304>.
- Wang, H., Shi, H., Lin, K., Qin, C., Zhao, L., Huang, Y., & Liu, C. (2020). A high-precision arrhythmia classification method based on dual fully connected neural network. *Biomedical Signal Processing and Control*, 58, 101874. <https://www.sciencedirect.com/science/article/pii/S1746809420300306>.
- WHO. (2021). Cardiovascular Diseases. https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_2.
- Xie, Y.-L., & Lin, C.-W. (2023). Imbalanced ectopic beat classification using a low-memory-usage CNN LMUEBCNet and correlation-based ECG signal oversampling. *Mathematics*, 11(8), 1833. <https://doi.org/10.3390/math11081833>
- Zheng, Z., Chen, Z., Hu, F., Zhu, J., Tang, Q., Liang, Y. (2020). An automatic diagnosis of arrhythmias using a combination of CNN and LSTM technology. *Electronics*, 9(1), 121-136. <https://doi.org/10.3390/electronics9010121>.