

# **Identifikasi Sinyal *Congestive Heart Failure* dengan Metode *Convolutional Neural Network 1D***

**MUHAMMAD ADNAN PRAMUDITO, YUNENDAH NUR FU'ADAH, RITA MAGDALENA, ACHMAD RIZAL, FAUZI FRAHMA TALININGSIH**

Fakultas Teknik Elektro, Telkom University  
Email : adnanpramudito@student.telkomuniversity.ac.id

*Received 17 Desember 2021 | Revised 4 Januari 2022 | Accepted 26 Januari 2022*

## **ABSTRAK**

*Penyakit jantung merupakan salah satu penyebab utama kematian di dunia. Salah satu penyakit jantung yang perlu diperhatikan adalah congestive heart failure (CHF). CHF adalah suatu kondisi di mana jantung tidak mampu memompa darah ke seluruh tubuh. Penyakit ini dapat didiagnosis dengan EKG. Oleh karena itu, pada penelitian ini dibuat sebuah sistem yang dapat mengidentifikasi penyakit CHF secara otomatis menggunakan metode convolutional neural network (CNN) dengan 4 hidden layer dan 16 output channel, fully connected layer, dan aktivasi Softmax. Data yang digunakan dalam penelitian ini diambil dari MITBIH dan BIDMC. Penlitian ini memberikan akurasi 100%, sehingga deteksi penyakit CHF otomatis membantu staf medis mendiagnosis pasien untuk menerima perawatan yang tepat.*

**Kata kunci:** Elektrokardiogram (EKG), Convolutional Neural Network (CNN), Normal Sinus Rhythm (NSR), Congestive Heart Failure (CHF)

## **ABSTRACT**

*Heart disease is one of the leading causes of death in the world. One of the heart diseases that need to be considered is congestive heart failure (CHF). CHF is a condition in which the heart is unable to pump blood throughout the body. ECG can diagnose this disease. Therefore, this study created a system that can automatically identify CHF disease using the convolutional neural network (CNN) method with four hidden layers and 16 output channels, a fully connected layer, and Softmax activation. The data used in this study were taken from MIT-BIH and BIDMC. In this study provides 100% accuracy. Automated CHF disease detection helps medical staff diagnose patients to receive appropriate treatment.*

**Keywords:** Electrocardiogram (ECG), Convolutional Neural Network (CNN), Normal Sinus Rhythm (NSR), Congestive Heart Failure (CHF)

## 1. PENDAHULUAN

Penyakit jantung memiliki angka kematian tertinggi di dunia. Menurut WHO, lebih dari 17 juta orang didunia telah meninggal karena penyakit jantung. Penderita penyakit ini akan terus bertambah setiap tahunnya. Sekitar 2,8 juta orang di Indonesia menderita penyakit jantung (**I. Firdaus, 2019**). Salah satu jenis penyakit jantung yang perlu diperhatikan adalah *congestive heart failure* (CHF).

CHF adalah ketidakmampuan jantung untuk memberikan suplai darah yang dibutuhkan tubuh. Setiap tahun, penyakit jantung ini terus bertambah hingga 26 juta kasus. Gangguan ini biasanya terjadi pada pasien di atas usia 60 tahun (**W. H. Federation, 2019**). Hal ini biasanya disebabkan oleh kelainan pada otot jantung yang membuat jantung tidak berfungsi dengan baik. Penyakit ini sangat berbahaya karena menyebabkan kegagalan organ lain, penyakit katup jantung, aritmia, serangan jantung mendadak dan bisa berakibat fatal. Penyakit ini tergolong berbahaya dan membutuhkan penanganan segera jika terdiagnosis (**Adrian, 2020**).

Elektrokardiogram (EKG) adalah sinyal periode tidak stabil yang menunjukkan aktivitas jantung (**E. Maharani, 2018**). Dokter dapat menggunakan EKG untuk mendiagnosis penyakit jantung pasien. Namun, ada beberapa hal yang perlu diperhatikan saat membaca sinyal EKG ini. Artinya, jika hasil yang diperoleh dalam kondisi abnormal tidak selalu menunjukkan adanya kelainan pada jantung, atau sebaliknya.

Banyak penelitian dalam beberapa tahun terakhir telah menggunakan machine learning untuk mengidentifikasi sinyal EKG dalam berbagai metode dan kumpulan data. Misalnya, Roberto A. dkk. Dilaporkan dalam studi diagnostik EKG otomatis menggunakan metode CNN, 47 catatan aritmia MITBIH mencapai akurasi 98,33% (**Avanzato & Beritelli, 2020**). PadmavathiC, dkk. Kajian deteksi penyakit jantung dari sinyal EKG menggunakan CNN menggunakan tiga database berbeda (database PTB, BIDMC, dan MITBIH) memiliki akurasi rata-rata 86% (**Padmavathi & Veenadevi, 2020**). Jian Lui dkk. Dengan mengklasifikasikan sinyal EKG menggunakan tiga metode (CNN, SVM, LD), akurasinya mencapai 91,29% (**Liu, Song, Sun, & Fu, 2019**). Zahra. E dkk. Menggunakan metode CNN, memeriksa metode *deep learning* untuk mengklasifikasikan sinyal EKG dan tiga set data (PhysioNet, MITDB, PTB) dengan akurasi rata-rata 99,83% (**Ebrahimi, Loni, Daneshtalab, & Gharehbarghi, 2020**). Chen Chen menunjukkan akurasi 97,15% dalam klasifikasi aritmia otomatis dengan kombinasi CNN dan LSTM (**Chen, Hua, Zhang, Liu, & Wen, 2020**). Limin Yu dkk. Sinyal EKG untuk mendeteksi penyakit jantung diklasifikasikan dengan akurasi 97,63% menggunakan metode CNN dan 48 entri database MITBIH (**Zhang, Yu, Ye, Zhuang, & Ma, 2018**). Senna Y.S. dan Limin Yu melakukan hal yang sama dengan akurasi 99,67% (**Huang, Chen, Yao, & He, 2019**). Rizal dkk. melakukan analisis EKG menggunakan metode Hjorth deskriptor seperti aktivitas, mobilitas, dan kompleksitas, menggunakan algoritma klasifikasi seperti k-mean clustering, k-nearest neighbor, dan multi-layer perceptron untuk mengklasifikasikan AF, CHF, dan NSR serta akurasi setiap sebesar 88,67%, 99,3%, dan 99,3% (**Hadiyoso, Rizal, & Aulia, 2019**).

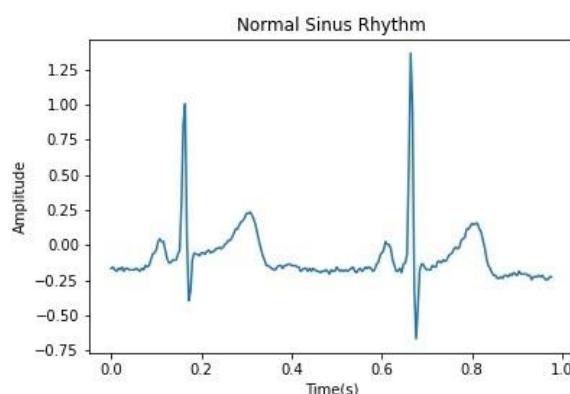
Beberapa penelitian sebelumnya telah melakukan beberapa tahapan penting dalam perancangan sistem pengenalan sinyal EKG, antara lain proses *preprocessing*, segmentasi, seleksi fitur, dan optimasi tingkat klasifikasi. Ini memiliki dampak yang signifikan pada kinerja sistem. Beberapa penelitian yang menggunakan CNN sebagai metode utama belum memberikan hasil yang lengkap. Di sisi lain, penelitian ini mengidentifikasi anomali sinyal EKG (EKG) menggunakan metode CNN satu dimensi, yang memiliki keunggulan menggunakan data yang terbatas untuk mengidentifikasi variasi sinyal tinggi yang dihasilkan oleh sumber

yang berbeda. Dataset yang diperoleh dari MITBIH dan BIDMC berisi 50 dataset per kelas. Ada dua kelas yang dievaluasi dalam penelitian ini: *normal sinus rhythm* (NSR) dan *congestive heart failure* (CHF). Melalui penelitian ini diharapkan kinerja sistem akan mengungguli penelitian sebelumnya.

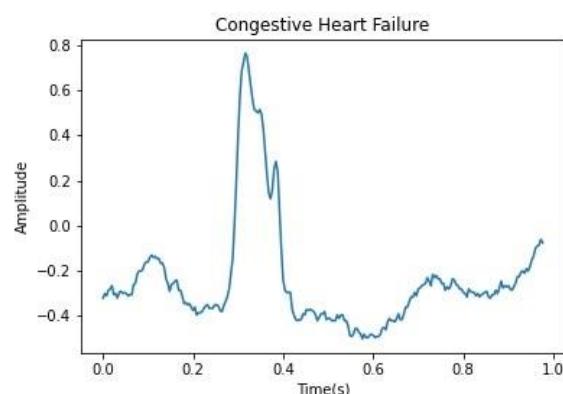
## 2. METODE PENELITIAN

### 2.1 Pengambilan Data Sinyal Elektrokardiogram (EKG)

Penelitian ini menggunakan data BIDMC dan MITBIH (**Baim DS, dkk, 2000**) (**George Moody, 1999**). Dataset terdiri dari dua jenis data: *normal sinus rhythm* (NSR) dan *congestive heart failure* (CHF). Contoh data untuk setiap kelas ditunjukkan pada Gambar 1 dan Gambar 2.



Gambar 1. Gelombang *Normal Sinus Rhythm* (NSR)



Gambar 2. Gelombang *Congestive Heart Failure* (CHF)

*Normal sinus rhythm* (NSR) adalah detak jantung normal. Kecepatan detak jantung ini adalah 60-100bpm. Untuk pria berusia 18 tahun, detak jantung yang sehat ditandai dengan ritme teratur 84 denyut per menit. Dataset NSR tidak menunjukkan CHF yang signifikan dan termasuk 5 pria berusia 26-45 tahun dan 13 wanita berusia 20-50 tahun (**George Moody, 1999**). Sedangkan 11 laki-laki usia 22-71 tahun dan 4 perempuan usia 54-63 tahun mengalami CHF dengan gagal jantung kongestif berat (**Baim DS, dkk, 2000**).

### 2.2 Convolutional Neural Networks (CNN)

CNN merupakan salah satu kelompok belajar yang diawasi. Tujuan pembuatan CNN adalah untuk melakukan pengenalan pola berdasarkan gambar dan suara yang sulit dipecahkan secara akurat (**Fu'adah, dkk., 2020**) (**Fu'adah, dkk., 2021**) (**O'Shea & Nash, 2015**). Keuntungan CNN terletak pada diskriminasinya dari data yang terbatas dan variabilitas sinyal yang tinggi yang dihasilkan oleh sumber yang berbeda (**Kiranyaz, dkk., 2021**). CNN dibagi menjadi dua bagian: *feature extraction* dan klasifikasi. Bagian ekstraksi fitur memiliki lapisan konvolusi, yang mulai diidentifikasi setelah memasuki program klasifikasi. Detail model CNN yang diusulkan (**Hadiyoso & Rizal, 2017**).

#### 2.2.1 Feature Extraction

*Feature extraction* adalah proses mengambil properti unik dari data yang sedang diproses (**Fu'adah, dkk., 2021**). Tujuan dari ekstraksi ciri adalah untuk mengurangi jumlah data, mendapatkan informasi penting dari data yang akan diolah, dan meningkatkan akurasi

pengolahan. Ada dua bagian untuk ekstraksi fitur, termasuk lapisan convolutional dan lapisan pooling (**Hadiyoso & Rizal, 2017**).

### **2.2.2 Convolutional Layer**

Pada layer ini, konvolusi dari setiap subregion data input dihitung oleh kernel, ditambah dengan bias, dan kemudian diinput oleh fungsi aktivasi untuk menghasilkan peta fitur di layer berikutnya (**Fu'adah, dkk., 2020**). Perambatan lapisan I ke neuron input pada lapisan konvolusi II dapat direpresentasikan dengan Persamaan (1) (**Eren, dkk., 2019**).

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

### **2.2.3 Pooling Layer**

*Pooling layer* berdasarkan *convolutional layer* adalah proses mendapatkan sampel yang digunakan untuk memperkecil ukuran fitur (**Fu'adah, dkk., 2021**). Minimalkan jaringan yang kompleks dan *overfitting* dengan mengurangi dimensi data keluaran dari lapisan konvolusi. Pada penelitian ini, lapisan *max pooling* diterapkan pada setiap lapisan convolutional (**Chen, dkk., 2020**).

$$o_i^{l,k} = f(\sigma_i^{l,k} \text{pool}(x_i^{i-1,k}) + b_i^{l,k}) \quad (2)$$

## **2.3 Klasifikasi**

Setelah melewati tahap ekstraksi ciri, maka dilakukan tahap klasifikasi. Klasifikasi ini digunakan untuk mengidentifikasi data yang diproses dengan ekstraksi ciri. Klasifikasi memiliki beberapa lapisan, lapisan datar dan lapisan yang terhubung penuh (**Fu'adah, dkk., 2021**) (**Patro, Jaya Prakash, dkk., 2020**).

### **2.3.1 Flatten Layer**

Hasil dari ekstraksi ciri adalah peta ciri berupa larik multidimensi yang perlu melalui proses perataan untuk menjadi vektor yang dapat digunakan sebagai masukan dari lapisan yang terhubung penuh. Dalam tugas akhir ini, *flatten layer* mengubah peta fitur menjadi vektor 1D untuk digunakan dengan layer yang terhubung penuh (**Chen, dkk., 2020**) (**Fu'adah, dkk., 2020**).

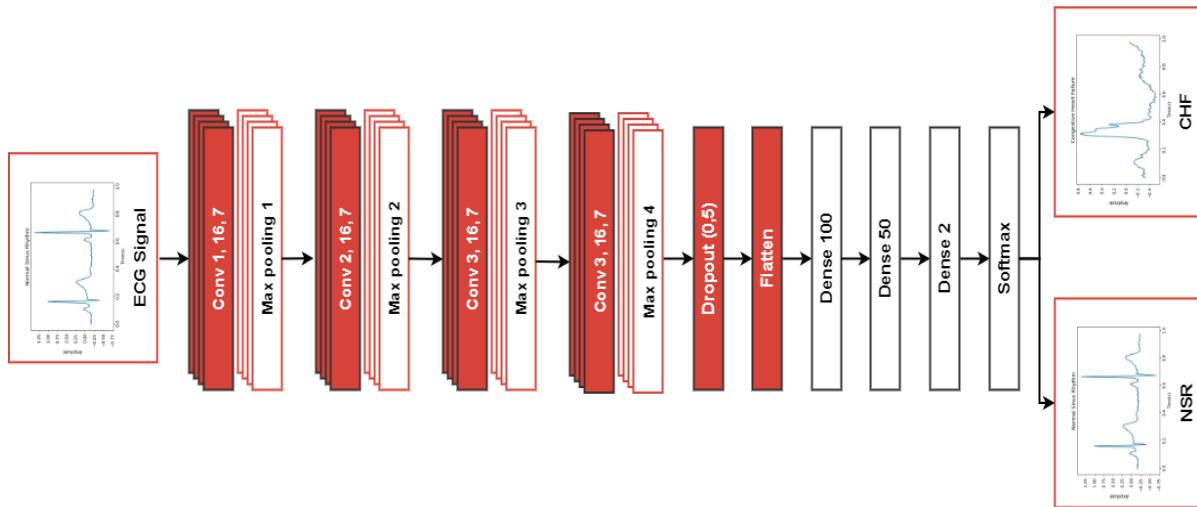
### **2.3.2 Fully Connected Layer**

*Fully connected layer* digunakan untuk menghubungkan semua fitur yang telah diekstraksi dari *flatten layer* (**Patro, dkk., 2020**). Dengan menggunakan klasifikasi regresi logistik, *softmax* activation akan mengklasifikasikan kondisi sinyal EKG (**Fu'adah, dkk., 2021**). Lapisan ini mentransfer jumlah dari lapisan sebelumnya ke fungsi aktivasi (**Patro, dkk., 2020**).

$$o_i^{l,k} = f(w_i^{l,k} x_i^{i-1,k} + b_i^{l,k}) \quad (3)$$

## **2.4 Desain Sistem yang Diusulkan**

100 sinyal EKG dari MITBIH dan BIDMC digunakan dalam penelitian ini. Setiap kelas berisi 50 catatan *normal sinus rhythm* (NSR) dan *congestive heart failure* (CHF). Penelitian ini menggunakan 90% data sebagai data pelatihan dan sisanya untuk data validasi. Model sistem yang digunakan dalam penelitian ini ditunjukkan pada Gambar 3.



**Gambar 3. Model yang diusulkan untuk Identifikasi Otomatis *Congestive Heart Failure* (CHF)**

Diagram alir sistem yang ditunjukkan pada gambar memiliki dua lapisan utama: ekstraksi fitur dan klasifikasi. Lapisan ekstraksi fitur memiliki empat lapisan tersembunyi, dan setiap lapisan tersembunyi memiliki lapisan konvolusi dan pooling maksimum. Setiap lapisan tersembunyi memiliki ukuran kernel dengan 16 dan 7 nilai filter. Ukuran penyatuan maksimum untuk setiap lapisan tersembunyi adalah 3, dan langkah atau pergeserannya adalah 1. Pada lapisan klasifikasi, klasifikasi dilakukan dengan menggunakan lapisan padat dan lapisan softmax, dan setiap lapisan padat memiliki jumlah neuron yang berbeda. Tugas akhir ini menggunakan tiga lapisan dense dengan jumlah neuron yaitu dense pertama 100, dense kedua 50, dan dense terakhir 2.

**Tabel 1. Detail Model CNN yang diusulkan**

<i>Layer</i>	<i>Output Shape</i>	<i>Parameter</i>
<i>Convolution</i>	$16 \times 16, 245$	128
<i>Max Pooling</i>	$16 \times 16, 81$	0
<i>Convolution</i>	$16 \times 16, 81$	1080
<i>Max Pooling</i>	$16 \times 16, 27$	0
<i>Convolution</i>	$16 \times 16, 27$	1080
<i>Max Pooling</i>	$16 \times 16, 9$	0
<i>Convolution</i>	$16 \times 16, 9$	1080
<i>Max Pooling</i>	$16 \times 16, 3$	0
<i>Dropout</i>	3	0
<i>Flatten</i>	48	0
<i>Dense</i>	100	4900
<i>Dense</i>	50	5050
<i>Dense</i>	2	102

## 2.5 Performansi Sistem

Penelitian ini menggunakan empat parameter yaitu akurasi, *recall*, presisi, dan *f1-score* untuk mengukur kinerja sistem. Pengukuran kinerja sistem ditunjukkan pada Persamaan (4), (5), (6), dan (7) (**Rizal, dkk., 2020**).

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (5)$$

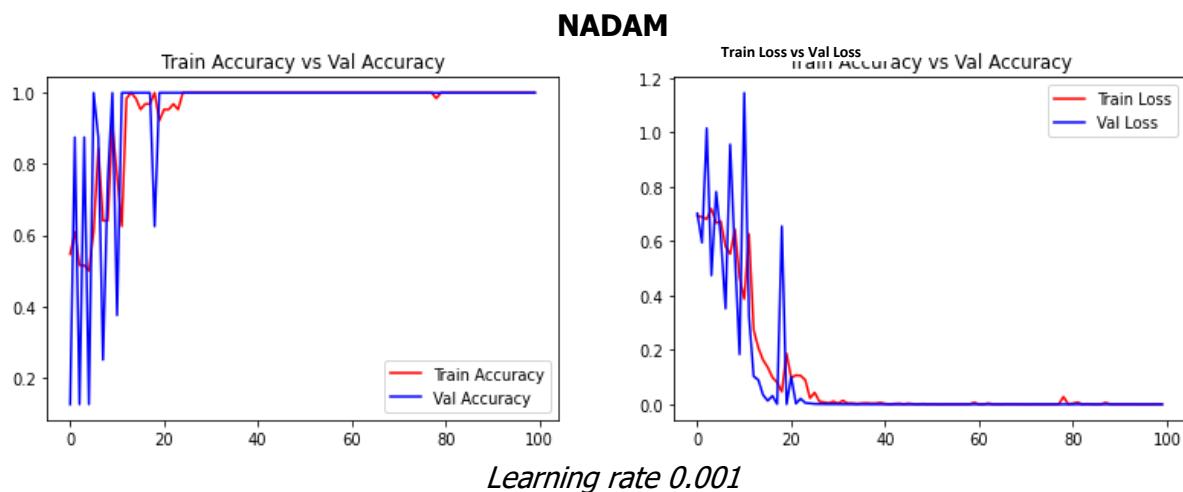
$$\text{Recall} = \frac{TP}{TP+FN} \quad (6)$$

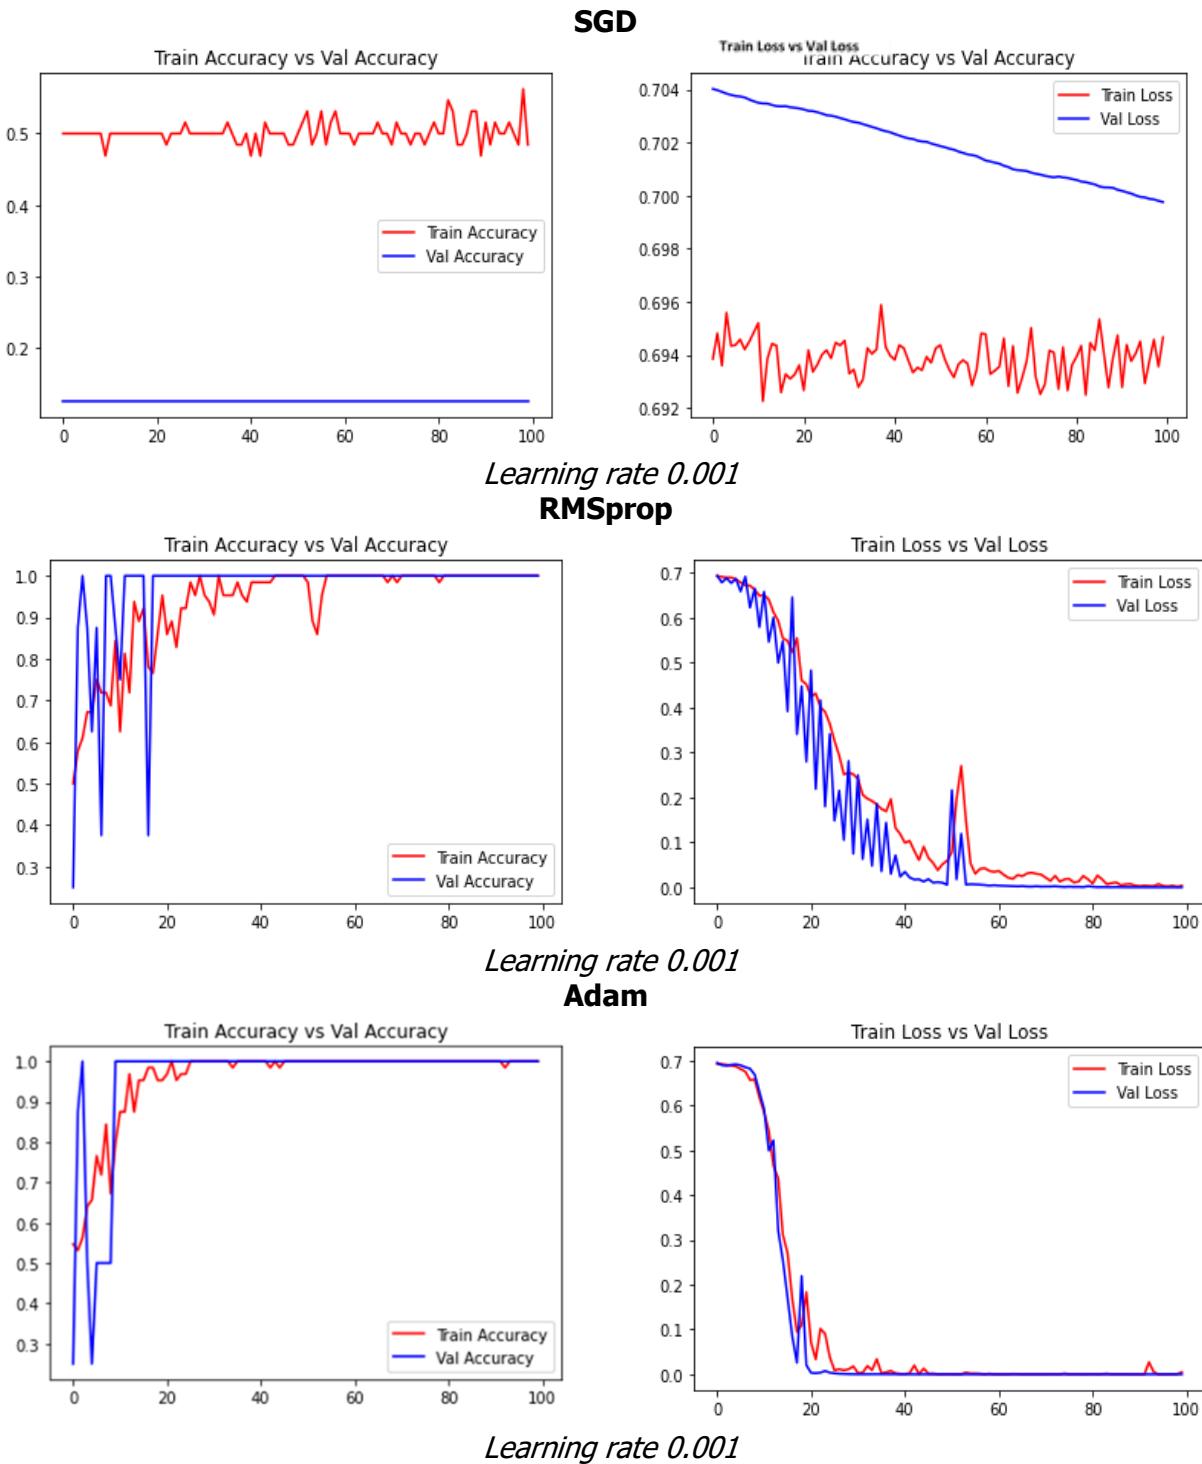
$$F1 - Score = 2 \times \frac{\text{recall} \times \text{precision}}{\text{recall} + \text{precision}} \quad (7)$$

*True Positive* (TP) mengidentifikasi data *congestive heart failure* (CHF) dan memprediksi *congestive heart failure* (CHF). *True Negative* (TN) mengidentifikasi data *normal sinus rhythm* (NSR) dan prediksi *normal sinus rhythm* (NSR). *False Positive* (FP) mengidentifikasi data *normal sinus rhythm* (NSR), tetapi memprediksi *congestive heart failure* (CHF). Identifikasi data *False Negative* (FN), *congestive heart failure* (CHF) dan *normal sinus rhythm* (NSR).

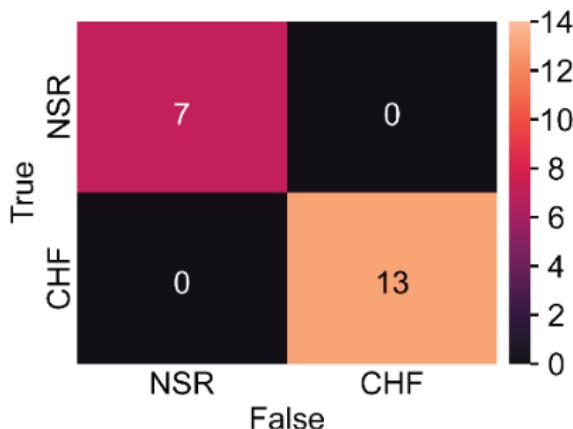
## 3. HASIL DAN PEMBAHASAN

Dataset EKG yang digunakan dalam penelitian ini terdiri dari 100 data rekaman *normal sinus rhythm* (NSR) dan *congestive heart failure* (CHF). Dataset yang digunakan pada pelatihan berisi 90 dataset dan 10 dataset digunakan untuk validasi data. Penelitian ini menggunakan CNN dengan berbagai pengoptimal dan kecepatan pembelajaran. Empat pengoptimal digunakan, termasuk Nadam, SGD, RMSprop dan Adam, dengan *learning rate* dalam kisaran 0,1, 0,01, 0,001 dan 0,0001. Penelitian ini memiliki empat parameter yaitu akurasi, memori, akurasi, dan f1Score. Hasil akurasi dan loss dari model yang diusulkan dalam penelitian ini ditunjukkan pada Gambar 4.





**Gambar 4. Perbandingan Akurasi, Loss, dan Optimizer dari Model yang diusulkan**

**Gambar 5. Confusion matrix Data Validasi**

Berdasarkan Gambar 4 diketahui bahwa semakin tinggi learning rate maka semakin besar loss yang biasa disebut dengan overshoot. Hasil terbaik dalam hal akurasi dan loss diperoleh dengan *learning rate* 0,001 dan *Nadam Optimizer*. Hal ini ditunjukkan dengan hasil akurasi konstan 1,0 ke-20 dari 100 epoch, tidak ada perbedaan akurasi antara data latih dan data validasi. Selain itu, nilai loss dari epoch ke-25 dari 100 stabil di 0, dan tidak ada perbedaan antara data latih dan data validasi. Gambar 4 menunjukkan bahwa semua data validasi yang digunakan diklasifikasikan dengan benar menurut kelasnya. Tabel ini menunjukkan hasil kinerja *recall*, *precision*, dan *f1-score* untuk nilai 1. Hasil ini menunjukkan bahwa model ini menjanjikan. Oleh karena itu, ketika menggunakan model yang diusulkan dengan *Nadam Optimizer* dan tingkat pembelajaran 0,001, kita dapat menyimpulkan bahwa hasil akurasi dan kerugian adalah 100% karena tidak ada *overfitting* atau *overshoot*.

**Tabel 2. Kinerja model sistem dalam penelitian ini**

<b>Class</b>	<b>Precision</b>	<b>Recall</b>	<b>F1-Score</b>
<i>Normal Sinus Rythm</i>	1,00	1,00	1,00
<i>Congesitive Heart Failure</i>	1,00	1,00	1,00

#### 4. KESIMPULAN

Klasifikasi *congestive heart failure* (CHF) secara otomatis berdasarkan pemrosesan sinyal audio menggunakan model CNN dengan empat lapisan tersembunyi dan empat lapisan pooling maksimum. Hasil eksperimen memberikan hasil terbaik ketika model yang diusulkan mengklasifikasikan dataset EKG ke dalam *normal sinus rythm* (NSR) dan *congestive heart failure* (CHF) menggunakan *Nadam Optimizer* dan *learning rate* 0,001. Ini menunjukkan bahwa. Hal ini didasarkan pada model dengan akurasi 100%, 0 untuk *loss*, nilai presisi, *recall*, dan *f1-score* sama dengan 1.

#### DAFTAR RUJUKAN

- Adrian, dr. K. (n.d.). (2021). Gagal jantung kongestif: Pembunuh diam-diam.
- Avanzato, R., & Beritelli, F. (2020). Automatic ECG Diagnosis Using Convolutional Neural Network. *MDPI*, 9, 1–14.

- Baim DS, Colucci WS, Monrad ES, Smith HS, Wright RF, Lanoue A, Gauthier DF, Ransil BJ, Grossman W, B. E. (2000). BIDMC Congestive Heart Failure Database. <https://doi.org/https://doi.org/10.13026/C29G60>
- Chen, C., Hua, Z., Zhang, R., Liu, G., & Wen, W. (2020). Automated arrhythmia classification based on a combination network of CNN and LSTM. *Biomedical Signal Processing and Control*, 57, 101819. <https://doi.org/10.1016/j.bspc.2019.101819>
- E. Maharani. (2018). Elektrokardiografi konsep dasar dan praktik klinik. *UGM Press*.
- Ebrahimi, Z., Loni, M., Daneshtalab, M., & Gharehbaghi, A. (2020). A review on deep learning methods for ECG arrhythmia classification. *Expert Systems with Applications: X*, 7, 100033. <https://doi.org/10.1016/j.eswax.2020.100033>
- Eren, L., Ince, T., & Kiranyaz, S. (2019). A Generic Intelligent Bearing Fault Diagnosis System Using Compact Adaptive 1D CNN Classifier. *Journal of Signal Processing Systems*, 91(2), 179–189. <https://doi.org/10.1007/s11265-018-1378-3>
- Fu'adah, Y. N., Pratiwi, N. C., Pramudito, M. A., & Ibrahim, N. (2020). Convolutional Neural Network (CNN) for Automatic Skin Cancer Classification System. *IOP Conference Series: Materials Science and Engineering*, 982(1). <https://doi.org/10.1088/1757-899X/982/1/012005>
- Fu'adah, Y. N., Saidah, S., Wijayanto, I., Ibrahim, N. A., Rizal, S., & Magdalena, R. (2021). *Computer Aided Diagnosis for Early Detection of Glaucoma Using Convolutional Neural Network (CNN)*.
- George Moody. (1999). MIT-BIH Normal Sinus Rhythm Database. <https://doi.org/https://doi.org/10.13026/C2NK5R>
- Hadiyoso, S., & Rizal, A. (2017). Electrocardiogram signal classification using higher-order complexity of hjorth descriptor. *Advanced Science Letters*, 23(5), 3972–3974. <https://doi.org/10.1166/asl.2017.8251>
- Hadiyoso, S., Rizal, A., & Aulia, S. (2019). ECG based person authentication using empirical mode decomposition and discriminant analysis. *Journal of Physics: Conference Series*, 1367(1). <https://doi.org/10.1088/1742-6596/1367/1/012014>
- Huang, J., Chen, B., Yao, B., & He, W. (2019). ECG Arrhythmia Classification Using STFT-Based Spectrogram and Convolutional Neural Network. *IEEE Access*, 7, 92871–92880. <https://doi.org/10.1109/ACCESS.2019.2928017>
- I. Firdaus. (n.d.). Hari jantung sedunia (world heart day): Your heart is our heart too perhimpunan dokter spesialis kardiovaskular indonesia (perki). Retrieved from <http://p2ptm.kemkes.go.id/kegiatan-p2ptm/>

- p2ptm/pusat-/hari-jantung-sedunia-world-heart-day-your-heart-is-our-heart-too
- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (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>
- Liu, J., Song, S., Sun, G., & Fu, Y. (2019). Classification of ECG Arrhythmia Using CNN, SVM and LDA. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11633 LNCS(2016), 191–201. [https://doi.org/10.1007/978-3-030-24265-7\\_17](https://doi.org/10.1007/978-3-030-24265-7_17)
- O'Shea, K., & Nash, R. (2015). *An Introduction to Convolutional Neural Networks*. 1–11. Retrieved from <http://arxiv.org/abs/1511.08458>
- Padmavathi, C., & Veenadevi, S. V. (2020). Heart disease recognition from ECG signal using deep learning. *International Journal of Advanced Science and Technology*, 29(5), 2303–2316.
- Patro, K. K., Jaya Prakash, A., Jayamanmadha Rao, M., & Rajesh Kumar, P. (2020). An Efficient Optimized Feature Selection with Machine Learning Approach for ECG Biometric Recognition. *IETE Journal of Research*, 60(0), 1–12. <https://doi.org/10.1080/03772063.2020.1725663>
- Rizal, S., Nor Kumalasari Caesar, Ibrahim, N., Vidya, H., Saidah, S., & Fu'adah, Y. N. (2020). *Tea Leaves Gmb Series Clasification Using Convolutional Neural Network*. 3(2), 0–5.
- W. H. Federation. (n.d.). World heart federation roadmap for heart failure. Retrieved from <https://www.world-heart-federation.org/cvd-roadmaps/><https://www.world-heart-federation.org/cvd-roadmaps/wrf-global-roadmaps/heart-failure/>
- Zhang, W., Yu, L., Ye, L., Zhuang, W., & Ma, F. (2018). ECG Signal Classification with Deep Learning for Heart Disease Identification. *International Conference on Big Data and Artificial Intelligence, BDAI 2018*, (pp. 47–51). <https://doi.org/10.1109/BDAI.2018.8546681>