



Prediksi Gagal Jantung Menggunakan Artificial Neural Network

Simeon Yuda Prasetyo

School of Computer Science, Computer Science Program, Universitas Bina Nusantara

Jl. K. H. Syahdan No. 9, Jakarta Barat, DKI Jakarta

Email: simeon.prasetyo@binus.ac.id

ABSTRACT

Cardiovascular disease or heart problems are the leading cause of death worldwide. According to World Health Organization (WHO) every year there are more than 17.9 million deaths worldwide. In previous studies, there have been many studies related to the application of machine learning to predict heart failure and obtained quite good results, ranging from 85% to 90%, with sophisticated models optimized using neural networks. In this research, experiments were carried out using similar architectures based on the state of the art from previous research, namely Artificial Neural Networks by conducting several hyperparameter tests, namely the number of hidden layers and the number of neuron units in the hidden layer. Based on the test results, the Artificial Neural Network model get the best results by implementing 2 hidden layers with 15 units of neurons in the first hidden layer and 10 units of neurons in the second hidden layer. This model get accuracy on data testing of 92,032% and AUC of 93%.

Keywords : heart failure prediction; artificial neural networks; machine learning

ABSTRAK

Penyakit kardiovaskular atau permasalahan jantung menjadi penyebab utama kematian di seluruh dunia. Menurut *World Health Organization* (WHO) setiap tahunnya terdapat lebih dari 17,9 juta kematian terjadi di seluruh dunia. Pada penelitian sebelumnya, sudah banyak penelitian yang muncul terkait penerapan *machine learning* untuk melakukan prediksi kegagalan jantung dan mendapatkan hasil yang cukup baik yakni berkisar 85% hingga 90% dengan *state of the art* model yang teroptimisasi menggunakan *neural network*. Pada penelitian ini dilakukan eksperimen menggunakan arsitektur sejenis berdasarkan *state of the art* dari penelitian sebelumnya yakni *Artificial Neural Network* dengan melakukan beberapa pengujian *hyperparameter* yaitu jumlah *hidden layer* dan jumlah unit neuron pada *hidden layer*. Berdasarkan hasil pengujian tersebut, model *Artificial Neural Network* mendapatkan hasil terbaik dengan mengimplementasikan 2 buah *hidden layer* dengan 15 unit neuron pada *hidden layer* pertama dan 10 unit neuron pada *hidden layer* kedua. Model ini berhasil mendapatkan akurasi pada data testing sebesar 92.032% dan AUC sebesar 93%.

Kata kunci : prediksi gagal jantung; artificial neural network; machine learning

1. PENDAHULUAN

Selama beberapa tahun terakhir, penyakit kardiovaskular (permasalahan jantung) tetap menjadi penyebab utama kematian di seluruh dunia. Perkiraan *World Health Organization* (WHO), setiap tahunnya terdapat lebih dari 17,9 juta kematian terjadi di seluruh dunia karena penyakit kardiovaskular ini. Dari sejumlah kematian ini, 80% disebabkan oleh penyakit arteri koroner dan stroke serebral (Seckeler & Hoke, 2011). Jumlah kematian akibat penyakit kardiovaskular ini proporsi paling besarnya terjadi di antara negara-negara berpenghasilan rendah dan menengah. Banyak faktor seperti kebiasaan pribadi dan faktor genetik yang dapat mempengaruhi dan menyebabkan penyakit jantung. Berbagai faktor risiko kebiasaan seperti merokok, konsumsi alkohol dan kafein berlebihan, stres dan aktivitas fisik bersama dengan faktor fisiologis lainnya seperti obesitas, hipertensi, kolesterol darah tinggi, dan kondisi jantung yang sudah ada sebelumnya merupakan faktor penyebab penyakit jantung (Gaziano et al., 2010). Diagnosis medis penyakit jantung yang efisien dan akurat serta dini memainkan peran penting dalam mengambil

tindakan pencegahan untuk mencegah kematian.

Seiring dengan perkembangan teknologi, proses prediksi gagal jantung ini dapat dilakukan dengan menggunakan pendekatan *machine learning* ataupun *data mining*. Beberapa penelitian yang sudah ada sebelumnya menunjukkan potensi hasil yang baik dalam prediksi penyakit jantung. Misalkan dalam (Anitha & Sridevi, 2019) membandingkan beberapa algoritma seperti SVM, KNN, dan Naive Bayes digunakan untuk memprediksi penyakit jantung. Algoritma pembelajaran mesin diimplementasikan menggunakan bahasa pemrograman R. Kinerja algoritma diukur menggunakan matriks akurasi dan didapatkan akurasi yang tertinggi sebesar 86.6% dengan algoritma Naive Bayes.

Penelitian lainnya (Mohan et al., 2019) melakukan berbagai penelitian dengan teknik *Machine Learning* dan mengusulkan sebuah metode baru yang bertujuan untuk menemukan fitur yang signifikan dengan menerapkan teknik *machine learning* yang menghasilkan peningkatan akurasi dalam prediksi penyakit kardiovaskular. Model prediksi diperkenalkan dengan kombinasi fitur

yang berbeda dan beberapa teknik klasifikasi yang dikenal. Menghasilkan akurasi kinerja terbaik 88,7% melalui model prediksi penyakit jantung dengan *Hybrid Random Forest Linear Model* (HRFLM).

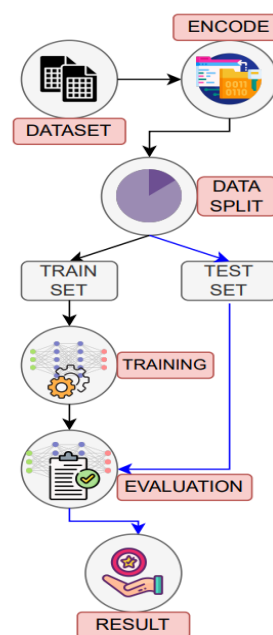
Penelitian sejenis yang dilakukan oleh Singh membandingkan KNN, SVM, *Linear Regression* dan *Decision Tree* untuk mendeteksi penyakit jantung mendapatkan akurasi tertinggi sebesar 87% dengan algoritma KNN (Singh & Kumar, 2020). Penelitian lainnya yang dilakukan oleh Amin, hasil percobaan menunjukkan bahwa model prediksi penyakit jantung yang dikembangkan menggunakan fitur signifikan yang teridentifikasi dan teknik *data mining* dengan performa terbaik (*Vote Naïve Bayes* dan *Logistic Regression*) mencapai akurasi 87,4% dalam prediksi penyakit jantung (Amin et al., 2019). Penelitian lainnya dengan *dataset* sejenis berhasil mendapatkan akurasi tertinggi sebesar 90,78% dengan model *Hyperparameter optimization* (Talos) yang mana menerapkan *artificial neural network* didalamnya (Sharma & Parmar, 2020).

Berdasarkan penelitian sebelumnya yang memanfaatkan pendekatan *machine learning* untuk

melakukan prediksi gagal jantung menunjukkan potensi yang baik yakni dengan capaian akurasi dari 86,6% hingga 90,78%. Dengan akurasi yang tertinggi yakni 90,78% didapatkan oleh *hyperparameter optimization* (Talos) model yang berbasis pada neural network. Namun, pada hasil yang terbaik ini tidak menampilkan *hyperparameter* pengujian pada *neural network* yang dihasilkan oleh Talos. Untuk itu, penelitian ini akan mencari konfigurasi secara lebih spesifik pada model neural network yakni dengan membandingkan parameter berupa jumlah *hidden layer* dan jumlah *unit neuron*.

2. METODE PENELITIAN

Berikut Gambar 1 tahapan penelitian.



Gambar 1. Tahapan Penelitian

Gambar 1 menjelaskan perancangan dan pembuatan model klasifikasi untuk memprediksi gagal jantung menggunakan model *Artificial Neural Network*. Bagian ini juga dilengkapi dengan penjelasan terkait dengan rancangan eksperimen dan *dataset* yang digunakan.

2.1. Dataset

Dataset yang digunakan dalam penelitian ini adalah Heart Failure Dataset yang bisa didapatkan melalui situs kaggle (*Kaggle*, n.d.). *Dataset* ini terdiri dari 918 data yang masing-masing terdiri dari 12 kolom dimana kolom berupa fitur dan 1 berupa output.

- *Age*: Usia
- *Sex*: Jenis kelamin
- *Chest Pain Type*: Nyeri Dada
- *Resting BP*: Tekanan darah saat istirahat
- *Cholesterol*: serum kolesterol
- *Fasting BS*: Gula darah puasa
- *Resting ECG*: hasil ecg istirahat
- *Max HR*: Detak jantung maksimum
- *Exercise Angina*: angina akibat olahraga
- *Old peak*: oldpeak = ST depression
- *ST Slope*: kemiringan segmen ST
- *Heart Disease*: kelas keluaran

2.1. Pra Pemrosesan Data

Tahapan pra pemrosesan data dilakukan sebelum menggunakan data dalam pelatihan dengan *machine learning* (dalam hal ini *neural network*). Dari seluruh data tersebut dilakukan *encode* data menggunakan *one-hot-encoding* pada kolom yang memiliki nilai bertipe kategorikal. *One-hot-encoding* dipilih karena penggunaan *integer encoding* tidak cocok karena bukan merupakan data ordinal (tingkatan tidak diketahui jarak pastinya).

Selain itu, dilakukan pula pembagian data menjadi *subset training* dan *testing*. Proporsi yang digunakan untuk *training* adalah 85% dengan data *testing* sejumlah 15%. Proporsi subset *training* sebesar 85% dipilih karena pada biasanya *subset training* memiliki proporsi antara 70% hingga 90%. Namun karena jumlah data yang digunakan tidak terlalu banyak (tidak mencapai 1000) maka jumlah data *training* lebih didekatkan pada batas atas yakni 85%.

2.2. Artificial Neural Network

Artificial Neural network (ANN) adalah *node* komputasi yang saling berhubungan sebagai inti dari algoritma *deep learning*. Elemen jaringan saraf disebut *perceptron* atau *neuron*, yang melakukan operasi aritmatika dan vektor dasar. Perceptron dapat digabungkan untuk bergantung pada hasil masing-masing untuk perhitungan lebih lanjut dan dengan demikian diatur dalam lapisan unit komputasi. Jaringan seperti itu disebut jaringan saraf. Membahas lebih detail tentang jaringan saraf, dimulai dengan unit dasar, perceptron, di bagian selanjutnya. Meskipun kesederhanaan desain adalah sumber signifikan dari kekuatan dan popularitas jaringan saraf, perhitungan ini sering tumbuh terlalu besar dan kompleks untuk diprogram dan dimanipulasi menggunakan alat pemrograman, yang menyebabkan munculnya kerangka kerja untuk jaringan pemrograman saraf (Prasetyo et al., 2022).

Pada dasarnya, *Artificial Neural Network* merupakan fungsi model matematika yang mendefinisikan $y = f(x * w)$ Dimana y merupakan output, f adalah fungsi aktivasi, x adalah sinyal masukan input dan w merupakan bobot dari sinaptik jaringan syaraf. Istilah jaringan merujuk pada interkoneksi pada

neuron pada lapisan-lapisan yang berbeda. Lapisan pada JST dibagi menjadi tiga bagian, antara lain :

- 1) *Input Layer*
- 2) *Hidden Layer*
- 3) *Output Layer*

Dalam penelitian ini, jumlah *neuron* yang digunakan dalam *hidden layer* akan diuji mana yang terbaik dari sejumlah 5, 10 dan 15 neuron dengan jumlah *hidden layer* yang diuji adalah satu dan dua *hidden layer*. Pemilihan jumlah neuron dalam *hidden layer* dan jumlah *hidden layer* digunakan sebagai batasan dalam penelitian ini.

Secara matematis, neuron merupakan sebuah fungsi yang menerima masukan dari lapisan sebelumnya x_i (lapisan ke- i). Fungsi ini pada umumnya mengolah sebuah vektor untuk kemudian diubah ke nilai skalar dengan menghitung *non linear weighted sum*. Fungsi dasar dari ANN dapat dilihat pada Persamaan 1.

$$f = A(\sum_i w_i x_i) \quad (1)$$

dimana A merupakan fungsi khusus yang sering disebut dengan fungsi aktivasi dan w_i merupakan bobot atau *weight*.

2.3. Matriks Evaluasi

Evaluasi yang digunakan dalam penelitian ini antara lain Akurasi, Recall Presisi, dan F1 Score. Confusion matrix pada kasus klasifikasi biner menyajikan kasus false positive (FP), false negative (FN) true positive (TP) dan true negative (TN) (Prasetyo, 2023).

Akurasi menjelaskan persentase seluruh data yang diklasifikasikan secara benar pada kelas positif ataupun negatif. Sehingga seluruh data prediksi yang bernilai benar dibagi dengan seluruh data yang tersedia (Prasetyo & Nabiilah, 2023). Sehingga akurasi dapat dituliskan sebagai Persamaan 2 berikut ini.

$$\text{Accuracy} = \frac{(TP+TN)}{(TP+TN+FN+FP)} \quad (2)$$

Recall (sensitivity) merupakan matriks pengukuran yang menghitung seberapa banyak Actual Positif yang berhasil ditangkap oleh model melalui pelabelannya sebagai Positif (memiliki nilai benar benar positif). Sehingga *recall* dapat dituliskan dalam Persamaan 3 berikut ini.

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

Precision atau yang mempunyai nama lain yakni *confidence* merupakan matriks yang membahas seberapa akurat suatu model yang dibuat. Hal ini dapat

diukur dari hasil prediksi yang memiliki nilai positif (seberapa banyak hasil yang diklasifikasikan dengan benar-benar positif) (Powers & Ailab, 2020). Sehingga precision ini bisa dirumuskan seperti pada Persamaan 4.

$$\text{Precision} = \frac{(TP)}{(TP+FP)} \quad (4)$$

F1-score adalah matriks untuk melakukan pengukuran dengan mempertimbangkan keselarasan antara antara *recall* dan *precision* sehingga pada f1-score tidak mempertimbangkan nilai dari negatif aktual (true negative). F1-score dapat dituliskan menjadi Persamaan 5.

$$\text{F1 - Score} = \frac{(2 \times \text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (5)$$

3. HASIL DAN PEMBAHASAN

Pengujian performa model dievaluasi menggunakan Google Colab Pro dengan bahasa pemrograman Python yang dipercepat oleh pengolahan unit grafis (GPU) dan RAM 25 GB. Pada pengimplementasian *Artificial Neural Network* pada *dataset* ini menunjukkan hasil yang baik, bahkan dapat mengalahkan akurasi penelitian sebelumnya yang juga menggunakan pendekatan *machine learning* lainnya.

Eksperimen ini dilakukan dengan *optimizer* adam, *learning rate* 0,001, fungsi aktivasi relu dan menggunakan iterasi sejumlah 1000. Hasil eksperimen prediksi atau klasifikasi biner gagal jantung dengan *Artificial Neural Network* ini dengan hyperparameter yang diuji berupa jumlah *hidden layer* dan jumlah neuron dapat dilihat pada Tabel 1.


Tabel 1. Hasil Eksperimen

| Hidden | Unit 1 | Unit 2 | Metric | Value |
|--------|--------|--------|-----------|--------|
| 1 | 5 | - | Accuracy | 0.9058 |
| | | | Precision | 0.9061 |
| | | | Recall | 0.899 |
| | | | F1-Score | 0.902 |
| | | | Time(ms) | 3.241 |
| 1 | 10 | - | Accuracy | 0.9203 |
| | | | Precision | 0.9213 |
| | | | Recall | 0.9139 |
| | | | F1-Score | 0.9171 |
| | | | Time(ms) | 3.9269 |
| 1 | 15 | - | Accuracy | 0.913 |
| | | | Precision | 0.909 |
| | | | Recall | 0.9129 |
| | | | F1-Score | 0.9108 |
| | | | Time(ms) | 3.0071 |
| 2 | 5 | 5 | Accuracy | 0.9058 |
| | | | Precision | 0.9061 |
| | | | Recall | 0.899 |
| | | | F1-Score | 0.902 |
| | | | Time(ms) | 3.6613 |
| 2 | 5 | 10 | Accuracy | 0.8986 |
| | | | Precision | 0.8973 |
| | | | Recall | 0.8928 |
| | | | F1-Score | 0.8948 |
| | | | Time(ms) | 2.5568 |
| 2 | 5 | 15 | Accuracy | 0.8841 |
| | | | Precision | 0.8846 |
| | | | Recall | 0.8752 |
| | | | F1-Score | 0.8791 |
| | | | Time(ms) | 2.6007 |
| 2 | 10 | 5 | Accuracy | 0.8913 |
| | | | Precision | 0.8873 |

| | | | | |
|---|----|----|-----------|--------|
| | | | Recall | 0.8892 |
| | | | F1-Score | 0.8882 |
| | | | Time(ms) | 2.9828 |
| 2 | 10 | 10 | Accuracy | 0.8913 |
| | | | Precision | 0.8865 |
| | | | Recall | 0.8918 |
| | | | F1-Score | 0.8887 |
| | | | Time(ms) | 3.5247 |
| 2 | 10 | 15 | Accuracy | 0.8986 |
| | | | Precision | 0.8973 |
| | | | Recall | 0.8928 |
| | | | F1-Score | 0.8948 |
| | | | Time(ms) | 4.3923 |
| 2 | 15 | 5 | Accuracy | 0.9058 |
| | | | Precision | 0.9037 |
| | | | Recall | 0.9016 |
| | | | F1-Score | 0.9026 |
| | | | Time(ms) | 3.5138 |
| 2 | 15 | 10 | Accuracy | 0.9203 |
| | | | Precision | 0.917 |
| | | | Recall | 0.9191 |
| | | | F1-Score | 0.918 |
| | | | Time(ms) | 2.022 |
| 2 | 15 | 15 | Accuracy | 0.8986 |
| | | | Precision | 0.8999 |
| | | | Recall | 0.8902 |
| | | | F1-Score | 0.8942 |
| | | | Time(ms) | 2.8734 |


Berdasarkan hasil eksperimen yang disajikan pada Tabel 1 tersebut, model *artificial neural network* terbaik didapatkan dengan 2 buah *hidden layer* dengan jumlah unit neuron pada *hidden layer* pertama sejumlah 15 dan jumlah unit neuron pada *hidden layer* kedua adalah 10 unit neuron. Dengan menggunakan arsitektur atau model ini berhasil mendapatkan akurasi testing sebesar 92,032. Selain itu, dari model terbaik ini berhasil mendapatkan komputasi waktu yang paling rendah yakni hanya dengan 2 mili detik.

Berdasarkan model terbaik yang berhasil dibentuk oleh *Artificial Neural Network*, arsitektur model dapat dilihat visualisasinya pada Gambar 2 dibawah ini.



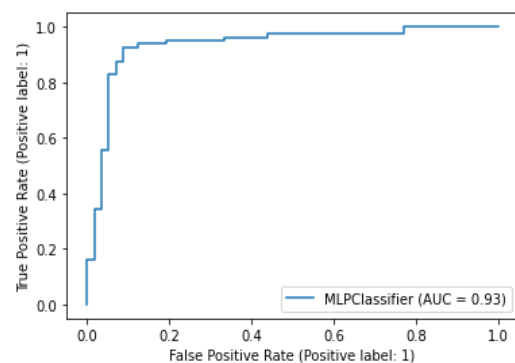
Gambar 2. Visualisasi Arsitektur

Dari model yang berhasil dibentuk dapat dilihat pula confusion matrix dan *ROC Curve* yang didapatkan. *Confusion matrix* dan *ROC Curve* ini dapat dilihat pada Gambar 3 dan Gambar 4 secara berturut-turut.



Gambar 3. *Confusion Matrix*
Confusion matrix yang

ditampilkan pada Gambar 3, bagian kiri atas merupakan *True Negative* (TN) berjumlah 52, bagian kanan atas merupakan *False Positive* (FP) berjumlah 5, bagian kiri bawah merupakan *False Negative* (FN) sejumlah 6, dan bagian kanan bawah adalah *True Positive* (TP) dengan jumlah 75. Dimana pada sumbu X dan sumbu Y terdapat angka nol dan satu, nol merepresentasikan kelas tidak gagal jantung (sehat) dan satu merupakan kelas gagal jantung.



Gambar 4. *ROC Curve*

Berdasarkan Gambar 4 terkait kurva *ROC (Receiver Operating Characteristic)* yang mana bertujuan untuk merepresentasikan grafis berdasarkan keterkaitan antara *True Positive Rate (TPR)* dan *False Positive Rate (FPR)*. Berdasarkan kurva tersebut dapat didapatkan *Area Under Curve (AUC)* sebesar 0,93. Hal ini berarti model mendapatkan hasil yang excellent (Patel & Sinha, 2015; Wahono et al., 2014).

4. KESIMPULAN

Telah terbukti bahwa implementasi *Artificial Neural Network* mampu mencapai skor akurasi uji klasifikasi yang tinggi pada prediksi gagal jantung biner atau tugas klasifikasi biner. Skor akurasi pengujian berhasil mencapai 92,032% dan AUC sebesar 93% yang diperoleh dengan menerapkan 2 buah hidden layer dan jumlah unit neuron pada lapisan tersembunyi sebanyak 15 unit untuk *hidden layer* pertama dan 10 untuk *hidden layer* kedua.

Sebagai saran untuk perbaikan model masa yang akan datang, dapat dilakukan optimasi dapat dilakukan di dengan mencari *hyperparameter* terbaik

dari model seperti jumlah unit neuron pada lapisan tersembunyi pada spektrum yang lebih luas, jenis fungsi aktivasi, *learning rate*, dan jenis *optimizer* yang digunakan.

DAFTAR PUSTAKA

- Amin, M. S., Chiam, Y. K., & Varathan, K. D. (2019). Identification of significant features and data mining techniques in predicting heart disease. *Telematics and Informatics*, 36, 82–93. <https://doi.org/10.1016/j.tele.2018.11.007>
- Anitha, S., & Sridevi, N. (2019). HEART DISEASE PREDICTION USING DATA MINING TECHNIQUES. In *Journal of Analysis and Computation*. www.ijaonline.com,
- Gaziano, T. A., Bitton, A., Anand, S., Abrahams-Gessel, S., & Murphy, A. (2010). Growing Epidemic of Coronary Heart Disease in Low- and Middle-Income Countries. *Current Problems in Cardiology*, 35(2), 72–115. <https://doi.org/10.1016/j.cpcardiol.2009.10.002>
- Kaggle. (n.d.). <https://www.kaggle.com/datasets>
- Mohan, S., Thirumalai, C., & Srivastava, G. (2019). Effective heart disease prediction using hybrid machine learning techniques. *IEEE Access*, 7, 81542–81554. <https://doi.org/10.1109/ACCESS.2019.2923707>
- Patel, B. C., & Sinha, G. R. (2015). Reliable Computer-aided Diagnosis System using Region based Segmentation of Mammographic

- Breast Cancer Images. *Mathematical Methods and Systems in Science and Engineering*, 296. <https://doi.org/10.35940/ijitee.C9009.019320>
- Powers, D. M. W., & Ailab. (2020). *EVALUATION: FROM PRECISION, RECALL AND F-MEASURE TO ROC, INFORMEDNESS, MARKEDNESS & CORRELATION*.
- Prasetyo, S. Y. (2023). SARS-CoV-2 Detection From Lung CT-scan Images Using Fine Tuning Concept on Deep-CNN Pretrained Model. *CESS (Journal of Computing Engineering, System and Science)*, 8(1), 101–112. www.jurnal.unimed.ac.id
- Prasetyo, S. Y., & Nabiilah, G. Z. (2023). Perbandingan Model Machine Learning Pada Klasifikasi Tumor Otak Menggunakan Fitur Discrete Cosine Transform. *Jurnal Teknologi Terpadu*, 9(1). <https://journal.nurulfikri.ac.id/index.php/jtt>
- Prasetyo, S. Y., Nabiilah, G. Z., & Nabila Izdihar, Z. (2022). *Age Estimation from Face Image using Discrete Cosine Transform Feature and Artificial Neural Network*.
- Seckeler, M. D., & Hoke, T. R. (2011). The worldwide epidemiology of acute rheumatic fever and rheumatic heart disease. In *Clinical Epidemiology* (Vol. 3, Issue 1, pp. 67–84). <https://doi.org/10.2147/CLEP.S12977>
- Sharma, S., & Parmar, M. (2020). Heart Diseases Prediction using Deep Learning Neural Network Model. *International Journal of Innovative Technology and Exploring Engineering*, 9(3), 2244–2248.