

Klasifikasi Risiko Penyakit Jantung Dengan Multilayer Perceptron

Irwan Daniel^{1)*}, Agus Fahmi Limas Ptr²⁾, Aulia Ichsan³⁾

^{1,2,3)} Universitas Deli Sumatera

¹⁾irwandaniel@gmail.com, ²⁾agusfahmilimasptr@gmail.com, ³⁾auliaichsan15@gmail.com

Received: 16 September 2024

Accepted: 22 September 2024

Published: 25 September 2024



[*irwandaniel@gmail.com](mailto:irwandaniel@gmail.com)

Kata Kunci: Penyakit Jantung, Multilayer Perceptron (MLP), ReLU, Tanh

DSI: Jurnal Data Science Indonesia is licensed under a Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0).

Abstrak : Penyakit jantung merupakan salah satu penyebab utama kematian di seluruh dunia, dengan deteksi dini yang seringkali menjadi tantangan karena gejala awalnya yang tidak spesifik. Penelitian ini bertujuan untuk mengevaluasi efektivitas model Multilayer Perceptron (MLP) dalam klasifikasi risiko penyakit jantung dengan membandingkan dua fungsi aktivasi, yaitu ReLU dan Tanh. Dataset yang digunakan terdiri dari 1190 entri dengan 11 fitur kesehatan, yang dibagi dalam rasio 80:20 untuk pelatihan dan pengujian. Model MLP dikembangkan dengan tiga lapisan tersembunyi, dan setiap model diterapkan dengan fungsi aktivasi ReLU dan Tanh untuk mengevaluasi performa masing-masing fungsi dalam mengklasifikasikan risiko penyakit jantung. Evaluasi model dilakukan menggunakan metrik akurasi, presisi, dan recall. Hasil penelitian menunjukkan bahwa model MLP dengan fungsi aktivasi ReLU memperoleh akurasi sebesar 81,51%, presisi 81,77%, dan recall 81,51%, sedangkan model dengan fungsi aktivasi Tanh mencapai akurasi 80,25%, presisi 80,32%, dan recall 80,25%. Perbedaan ini mengindikasikan bahwa ReLU unggul dalam hal akurasi dan metrik evaluasi lainnya, menjadikannya pilihan yang lebih efektif untuk deteksi dini penyakit jantung. Temuan ini memberikan insight berharga tentang bagaimana pemilihan fungsi aktivasi dapat mempengaruhi kinerja model dalam klasifikasi risiko penyakit, serta menggarisbawahi pentingnya pemilihan teknik yang tepat untuk meningkatkan akurasi deteksi dalam aplikasi medis.

PENDAHULUAN

Penyakit jantung merupakan kondisi medis yang melibatkan gangguan pada jantung dan pembuluh darah, yang dapat mengarah pada komplikasi serius seperti serangan jantung dan gagal jantung [1]. Deteksi dini penyakit jantung seringkali menjadi tantangan karena gejala awalnya sering kali tidak spesifik dan dapat disalahartikan sebagai kondisi lain, serta adanya variabilitas individu dalam risiko dan manifestasi penyakit [2]. Dalam menghadapi tantangan ini, machine learning menawarkan solusi potensial melalui pengembangan model prediksi yang dapat menganalisis data kesehatan secara komprehensif dan mengidentifikasi pola yang mungkin tidak terlihat oleh metode konvensional [3]. Dengan menggunakan algoritma machine learning, model deteksi dini dapat dikembangkan untuk memperkirakan risiko terjadinya penyakit jantung dengan lebih akurat, memungkinkan intervensi yang lebih cepat dan strategi pencegahan yang lebih efektif.

Dalam machine learning, klasifikasi digunakan untuk memprediksi risiko penyakit jantung dengan mengkategorikan data pasien ke dalam kelas risiko tertentu berdasarkan fitur-fitur kesehatan mereka [4]. Salah satu algoritma populer dalam klasifikasi adalah Artificial Neural Network (ANN), yang meniru cara kerja otak manusia dalam memproses informasi [5]. ANN terdiri dari lapisan neuron yang saling terhubung, termasuk lapisan input, lapisan tersembunyi, dan lapisan output [6]. Arsitektur ANN memungkinkan model untuk belajar dari data melalui proses pelatihan yang melibatkan penyesuaian bobot antar neuron, sehingga dapat menangkap pola kompleks dalam data yang mungkin tidak terdeteksi oleh algoritma lain [6]. Kelebihan utama ANN dalam permasalahan klasifikasi adalah kemampuannya untuk mengatasi data non-

linear dan mengadaptasi struktur model sesuai dengan kompleksitas data, yang sangat berguna dalam memprediksi risiko penyakit jantung dengan akurasi tinggi [7].

Multilayer Perceptron (MLP) merupakan salah satu algoritma dari Artificial Neural Network (ANN) yang populer dalam aplikasi machine learning, terutama dalam tugas klasifikasi dan prediksi. MLP terdiri dari beberapa lapisan neuron, yaitu lapisan input, satu atau lebih lapisan tersembunyi, dan lapisan output, yang memungkinkan model untuk belajar representasi fitur yang kompleks dan non-linear dari data [8]. Keunggulan utama MLP terletak pada kemampuannya dalam menangkap pola yang tidak dapat diidentifikasi oleh model linear atau metode klasifikasi sederhana lainnya, berkat struktur jaringannya yang mendalam dan proses pembelajaran berbasis backpropagation [9].

Beberapa penelitian telah menunjukkan efektivitas MLP dalam memprediksi penyakit dengan akurasi yang tinggi. Sebagai contoh, sebuah mengaplikasikan MLP untuk memprediksi risiko diabetes tipe 2 dan menemukan bahwa model ini menghasilkan akurasi yang sangat baik dalam klasifikasi berdasarkan data kesehatan pasien [10]. Penelitian lain menunjukkan penggunaan MLP dalam mendeteksi penyakit jantung dengan tingkat akurasi tinggi, berkat kemampuannya dalam menangani data non-linear dan kompleks [11]. Selain itu, penelitian yang mengaplikasikan MLP dalam prediksi kanker payudara menunjukkan bahwa MLP dapat memberikan prediksi yang akurat dan dapat diandalkan, memperkuat bukti bahwa MLP adalah alat yang sangat efektif dalam konteks medis [12].

Akurasi Multilayer Perceptron (MLP) sangat dipengaruhi oleh pemilihan fungsi aktivasi, yang memainkan peran kunci dalam menentukan kinerja model [13]. Fungsi aktivasi yang berbeda dapat mempengaruhi bagaimana model belajar dari data dan, pada akhirnya, akurasi serta metrik evaluasi lainnya [14]. Penelitian oleh [15] menunjukkan bahwa pemilihan fungsi aktivasi seperti ReLU dan Tanh dapat mempengaruhi kecepatan konvergensi serta performa akhir model, dengan ReLU sering kali memberikan hasil yang lebih baik dalam hal akurasi. Sebuah studi oleh [16] juga membuktikan bahwa fungsi aktivasi ReLU dan variannya dapat menghasilkan performa yang lebih baik dibandingkan Tanh pada data dengan dimensi tinggi. Selain itu, penelitian oleh [17] mengamati perbedaan signifikan dalam metrik evaluasi antara berbagai fungsi aktivasi, menekankan pentingnya pemilihan fungsi yang tepat untuk mencapai hasil yang optimal. Penelitian ini akan membahas permasalahan ini dengan membandingkan dua fungsi aktivasi populer, ReLU dan Tanh, untuk mengevaluasi bagaimana masing-masing mempengaruhi akurasi dan metrik evaluasi model MLP, sehingga memberikan wawasan yang lebih mendalam tentang dampak pemilihan fungsi aktivasi terhadap performa model dalam konteks prediksi penyakit.

Penelitian ini bertujuan untuk mengklasifikasikan gejala penyakit jantung agar dapat dikategorikan ke dalam tingkat risiko yang berbeda, yaitu "Tidak Berisiko" dan "Berisiko." Dataset yang digunakan akan dibagi dengan rasio 80:20, dimana 80% digunakan untuk pelatihan model dan 20% untuk pengujian. Dalam penelitian ini, dua fungsi aktivasi yang populer, yaitu ReLU dan Tanh, akan diterapkan dalam model klasifikasi untuk membandingkan kinerja masing-masing. Penggunaan fungsi aktivasi ini bertujuan untuk mengevaluasi bagaimana masing-masing mempengaruhi akurasi klasifikasi. Metrik evaluasi seperti Akurasi, Presisi, dan Recall akan digunakan untuk membandingkan performa kedua model dan menentukan fungsi aktivasi yang memberikan hasil terbaik dalam prediksi risiko penyakit jantung.

TINJAUAN LITERATUR

Pemanfaatan Multilayer Perceptron (MLP) dalam permasalahan klasifikasi untuk memprediksi penyakit telah terbukti efektif dalam berbagai penelitian. Sebagai contoh, studi oleh [10] menunjukkan bahwa MLP digunakan untuk memprediksi risiko diabetes tipe 2 dengan hasil yang memuaskan, di mana model ini mampu mengidentifikasi pasien berisiko tinggi berdasarkan fitur medis dengan akurasi yang tinggi. Penelitian oleh [11] menerapkan MLP untuk klasifikasi kanker payudara, di mana model ini menunjukkan performa yang kuat dalam mendeteksi tumor ganas dari data citra medis, memberikan hasil yang lebih akurat dibandingkan metode lain. Selain itu, penelitian oleh [12] mengaplikasikan MLP dalam memprediksi risiko penyakit jantung, dan menemukan bahwa model ini dapat memberikan prediksi yang andal dan akurat, memperlihatkan kemampuannya dalam menangani data kesehatan yang kompleks. Ketiga artikel ini menunjukkan bahwa MLP adalah alat yang efektif dalam klasifikasi penyakit, menawarkan solusi yang robust untuk memprediksi berbagai kondisi medis.

Pemilihan fungsi aktivasi ReLU dalam model Multilayer Perceptron (MLP) sering kali terbukti lebih unggul dibandingkan dengan Tanh dalam permasalahan klasifikasi penyakit jantung, seperti yang diungkapkan dalam beberapa penelitian. Penelitian oleh [18] menunjukkan bahwa ReLU memberikan performa yang superior dibandingkan Tanh dalam klasifikasi risiko penyakit jantung, dengan hasil yang lebih baik dalam hal akurasi dan kecepatan konvergensi model. Selain itu, studi oleh [19] membandingkan ReLU dan Tanh dalam konteks prediksi penyakit jantung dan menemukan bahwa ReLU mengatasi masalah vanishing gradient secara efektif, menghasilkan model yang lebih stabil dan akurat. Penelitian oleh [20] juga mengkonfirmasi keunggulan ReLU dalam MLP untuk klasifikasi penyakit jantung, menunjukkan bahwa ReLU tidak hanya meningkatkan akurasi tetapi juga mempercepat proses pelatihan model dibandingkan dengan Tanh. Ketiga artikel ini menggarisbawahi keuntungan penggunaan ReLU dalam MLP, terutama dalam konteks klasifikasi penyakit jantung, berkat kemampuannya untuk menangani data yang kompleks dengan lebih efisien.

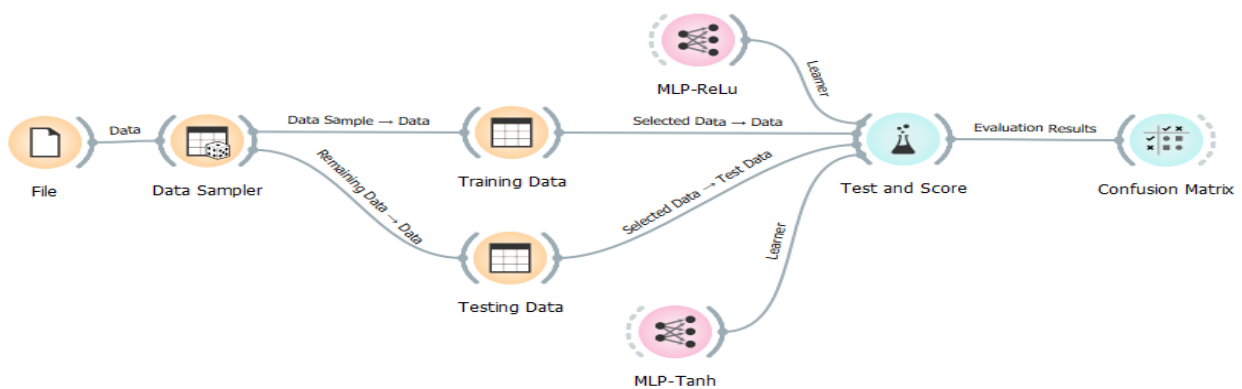
Pemilihan fungsi aktivasi Tanh dalam model Multilayer Perceptron (MLP) menunjukkan keunggulan tertentu dibandingkan dengan ReLU dalam permasalahan klasifikasi penyakit jantung, seperti yang dijelaskan dalam berbagai studi. Penelitian oleh [21] menunjukkan bahwa Tanh dapat memberikan performa yang lebih baik dalam hal akurasi dan presisi untuk klasifikasi penyakit jantung, terutama dalam situasi di mana data memiliki skala yang berbeda-beda dan memerlukan normalisasi yang lebih baik. Selain itu, studi oleh [22] mengidentifikasi bahwa Tanh mengurangi masalah vanishing gradient yang sering ditemui dalam ReLU ketika bekerja dengan data yang lebih kecil atau dataset yang memiliki distribusi fitur yang berbeda. Penelitian oleh [23] juga mengkonfirmasi bahwa penggunaan Tanh dalam MLP untuk klasifikasi penyakit jantung dapat meningkatkan kualitas model dengan memberikan representasi non-linear yang lebih halus, yang berkontribusi pada hasil yang lebih akurat dibandingkan dengan ReLU pada beberapa kondisi dataset. Ketiga artikel ini menunjukkan bahwa Tanh dapat menjadi pilihan yang lebih baik dalam situasi tertentu, memberikan keuntungan dalam akurasi dan stabilitas model MLP dalam klasifikasi penyakit jantung.

Berdasarkan artikel penelitian terkait, Multilayer Perceptron (MLP) terbukti efektif untuk digunakan dalam model klasifikasi penyakit, khususnya dalam prediksi risiko penyakit jantung. Penelitian menunjukkan bahwa MLP dapat menangani data yang kompleks dan memberikan hasil akurat dalam klasifikasi risiko penyakit. Dalam konteks ini, pemilihan fungsi aktivasi seperti ReLU dan Tanh memainkan peran penting dalam mempengaruhi kinerja model. Fungsi aktivasi ReLU sering kali unggul dalam hal kecepatan pelatihan dan konvergensi, terutama pada dataset besar dan kompleks, berkat kemampuannya untuk mengatasi masalah vanishing gradient. Sebaliknya, fungsi aktivasi Tanh dapat memberikan hasil yang lebih baik dalam situasi di mana data memerlukan normalisasi yang lebih baik dan dalam dataset dengan distribusi fitur yang berbeda, karena Tanh mengatasi masalah dengan skala data yang lebih baik. Perbedaan dalam performa ini menunjukkan pentingnya pemilihan fungsi aktivasi yang sesuai untuk mengoptimalkan akurasi dan efisiensi model MLP dalam klasifikasi risiko penyakit jantung pada berbagai jenis dataset.

METODE PENELITIAN

Dataset yang digunakan dalam penelitian ini diambil dari situs web Kaggle.com [24], yang menyediakan berbagai kumpulan data untuk analisis dan pemodelan. Dataset ini terdiri dari 1190 entri, masing-masing dengan 11 fitur yang menggambarkan kategori gejala risiko penyakit jantung. Untuk memastikan keakuratan dan keberhasilan model, dataset dibagi dengan rasio 80:20, di mana 80% data digunakan untuk proses pelatihan model dan 20% sisanya digunakan untuk pengujian. Pembagian ini bertujuan untuk mengoptimalkan kinerja model dalam mengklasifikasikan risiko penyakit jantung dan untuk memvalidasi hasil yang diperoleh secara objektif.

Model dalam penelitian ini dirancang menggunakan aplikasi Orange Data Mining, dengan memanfaatkan widget "Learner Neural Network" untuk membangun struktur MLP, seperti terlihat pada Gambar 1.



Gambar 1 Model Klasifikasi MLP Menggunakan Orange Data Mining

Konfigurasi model mencakup tiga lapisan tersembunyi, masing-masing dengan 10 neuron, yang dirancang untuk menangkap pola kompleks dalam data. Pada setiap model, diterapkan dua fungsi aktivasi yang berbeda, yaitu ReLU dan Tanh, untuk mengevaluasi pengaruh fungsi aktivasi terhadap kinerja klasifikasi, dengan rincian seperti terlihat pada Tabel 1.

Tabel 1 Konfigurasi Model

Model	Neuron	Fungsi Aktivasi	Fungsi Optimasi
MLP-ReLu	10-10-10	ReLu	Adam
MLP-Tanh	10-10-10	Tanh	Adam

Fungsi aktivasi ReLU (Rectified Linear Unit) didefinisikan dengan formula (1):

$$ReLU(x) = \max(0, x) \quad (1)$$

di mana output adalah nilai input yang positif atau nol jika inputnya negatif. ReLU dikenal karena kemampuannya dalam mempercepat pelatihan model dan mengurangi masalah vanishing gradient, menjadikannya pilihan populer untuk berbagai aplikasi jaringan saraf [25].

Sebaliknya, fungsi aktivasi Tanh (Hyperbolic Tangent) dihitung dengan formula (2):

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

yang menghasilkan output dalam rentang -1 hingga 1. Tanh sering digunakan karena kemampuannya dalam menangani data yang terdistribusi secara simetris dan mengatasi masalah skala data. Kedua fungsi ini diterapkan dalam model MLP untuk mengevaluasi dampaknya terhadap kinerja klasifikasi dalam konteks prediksi risiko penyakit jantung [26].

Evaluasi kinerja dilakukan menggunakan widget "Test & Score," yang mengukur performa model berdasarkan metrik akurasi, presisi, dan recall. Pendekatan ini memungkinkan analisis komprehensif terhadap efektivitas berbagai konfigurasi dan fungsi aktivasi dalam memprediksi risiko penyakit jantung. Akurasi mengukur proporsi prediksi yang benar dibandingkan dengan total prediksi, dihitung dengan formula (3) [27]:

$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Prediksi} \quad (3)$$

Presisi mengukur proporsi prediksi positif yang benar dibandingkan dengan total prediksi positif, dengan formula (4) [27]:

$$Presisi = \frac{True\ Positives}{True\ Positive + False\ Positive} \quad (4)$$

penting untuk menilai sejauh mana model dapat mengidentifikasi kasus positif dengan benar.

Recall, atau sensitivitas, mengukur proporsi kasus positif yang benar-benar terdeteksi dibandingkan dengan total kasus positif yang sebenarnya, dihitung dengan formula (5) [27]:

$$Recall = \frac{True\ Positives}{True\ Positive + False\ Negative} \quad (5)$$


Ketiga metrik ini memberikan gambaran komprehensif tentang performa model dalam mengklasifikasikan risiko penyakit jantung dan membantu dalam memilih model yang paling efektif.

HASIL PENELITIAN

Hasil pelatihan model (Tabel 2) menunjukkan perbedaan kinerja antara MLP dengan fungsi aktivasi ReLU dan Tanh dalam klasifikasi risiko penyakit jantung. Model MLP dengan fungsi aktivasi ReLU mencapai nilai akurasi sebesar 0.896, dengan metrik presisi dan recall masing-masing sebesar 0.897, menunjukkan kinerja yang konsisten dalam mengidentifikasi risiko penyakit jantung. Sebaliknya, model MLP dengan fungsi aktivasi Tanh menunjukkan hasil yang sedikit lebih baik, dengan nilai akurasi 0.899 dan metrik presisi serta recall masing-masing 0.900. Hasil ini mengindikasikan bahwa fungsi aktivasi Tanh memberikan performa yang lebih optimal dalam hal akurasi, presisi, dan recall, dibandingkan dengan ReLU, pada dataset yang digunakan dalam penelitian ini. Perbedaan ini menyoroti pentingnya pemilihan fungsi aktivasi yang tepat dalam mengoptimalkan kinerja model klasifikasi untuk prediksi risiko penyakit jantung. Dari hasil proses pelatihan, diperoleh confusion matrix untuk kedua model, yang ditampilkan pada Gambar 2.

Tabel 2 Hasil Pelatihan Model

Model	Akurasi	Presisi	Recall
MLP-ReLu	0,8960	0,8968	0,8960
MLP-Tanh	0,8992	0,8999	0,8992



Gambar 2 Confusion Matrix Proses Pelatihan


Confusion matrix pada Gambar 2 memberikan gambaran yang jelas mengenai performa masing-masing model dalam mengklasifikasikan risiko penyakit jantung. Untuk model MLP-ReLU, confusion matrix menunjukkan distribusi prediksi antara kelas "Berisiko" dan "Tidak Berisiko," dengan nilai yang mendekati keseimbangan antara true positives, true negatives, false positives, dan false negatives. Sementara itu, confusion matrix untuk model MLP-Tanh mengindikasikan hasil yang sedikit lebih baik, dengan proporsi true positives yang lebih tinggi dan false negatives yang lebih rendah. Perbandingan antara kedua confusion matrix ini menggarisbawahi bahwa model MLP-Tanh memiliki keunggulan dalam mengidentifikasi risiko penyakit jantung dengan lebih akurat, yang konsisten dengan hasil metrik evaluasi sebelumnya.

Hasil pengujian model Multilayer Perceptron (MLP) dengan dua fungsi aktivasi yang berbeda, yaitu ReLU dan Tanh, menunjukkan perbedaan performa dalam klasifikasi risiko penyakit jantung, seperti terlihat pada Tabel 2. Pada model MLP dengan fungsi aktivasi ReLU, akurasi yang diperoleh adalah 81,51%, dengan precision sebesar 81,77%, dan recall sebesar 81,51%. Di sisi lain, model MLP dengan fungsi aktivasi Tanh menghasilkan akurasi yang lebih rendah, yaitu 80,25%, precision sebesar 80,32%, dan recall sebesar 80,25%. Berdasarkan hasil ini, dapat disimpulkan bahwa penggunaan fungsi aktivasi ReLU lebih unggul dibandingkan Tanh dalam mengklasifikasikan risiko penyakit jantung pada dataset yang digunakan, karena memberikan nilai akurasi, precision, dan recall yang lebih tinggi. Dari hasil proses pengujian, diperoleh confusion matrix untuk kedua model, yang ditampilkan pada Gambar 3.

Tabel 3 Hasil Pengujian Model

Model	Akurasi	Presisi	Recall
MLP-ReLu	0,8151	0,8178	0,8151

MLP-Tanh	0,8025	0,8033	0,8025
----------	--------	--------	--------



. Gambar 3 Confusion Matrix Proses Pengujian

Confusion matrix pada Gambar 3 memberikan gambaran yang jelas mengenai performa masing-masing model dalam mengklasifikasikan risiko penyakit jantung. Untuk model MLP-ReLU, confusion matrix menunjukkan distribusi prediksi antara kelas "Berisiko" dan "Tidak Berisiko," dengan nilai yang mendekati keseimbangan antara true positives, true negatives, false positives, dan false negatives. Sementara itu, confusion matrix untuk model MLP-Tanh mengindikasikan hasil yang sedikit lebih baik, dengan proporsi true positives yang lebih tinggi dan false negatives yang lebih rendah. Perbandingan antara kedua confusion matrix ini menggarisbawahi bahwa model MLP-Tanh memiliki keunggulan dalam mengidentifikasi risiko penyakit jantung dengan lebih akurat, yang konsisten dengan hasil metrik evaluasi sebelumnya.

PEMBAHASAN

Hasil pelatihan model MLP dengan fungsi aktivasi ReLU ditunjukkan melalui confusion matrix di atas. Dari 439 sampel yang sebenarnya tidak berisiko (kelas 0), model mampu mengklasifikasikan 376 sampel dengan benar (True Negative) dan salah mengklasifikasikan 63 sampel sebagai berisiko (False Positive). Sementara itu, dari 513 sampel yang sebenarnya berisiko (kelas 1), model berhasil mengklasifikasikan 477 sampel dengan benar (True Positive) dan salah mengklasifikasikan 36 sampel sebagai tidak berisiko (False Negative). Confusion matrix ini menunjukkan bahwa model memiliki kemampuan yang baik dalam mengidentifikasi risiko penyakit jantung, dengan jumlah kesalahan klasifikasi yang relatif rendah pada kedua kelas. Berdasarkan confusion matrix dari hasil pengujian model MLP dengan fungsi aktivasi ReLU, model menunjukkan performa yang cukup baik dalam klasifikasi risiko penyakit jantung. Dari 122 sampel yang sebenarnya tidak berisiko (kelas 0), model berhasil mengklasifikasikan 95 sampel dengan benar (True Negative), namun salah mengklasifikasikan 27 sampel sebagai berisiko (False Positive). Sementara itu, dari 116 sampel yang sebenarnya berisiko (kelas 1), model berhasil mengklasifikasikan 99 sampel dengan benar (True Positive) dan salah mengklasifikasikan 17 sampel sebagai tidak berisiko (False Negative). Hasil ini menunjukkan bahwa model cenderung lebih akurat dalam mendeteksi sampel yang berisiko (kelas 1) dibandingkan sampel yang tidak berisiko, meskipun terdapat kesalahan klasifikasi yang cukup signifikan pada kedua kelas.

Berdasarkan hasil pelatihan dan pengujian model MLP dengan fungsi aktivasi ReLU, dapat disimpulkan bahwa model memiliki kemampuan yang baik dalam mendeteksi gejala risiko penyakit jantung. Model menunjukkan akurasi yang tinggi dalam mengidentifikasi sampel berisiko, dengan tingkat True Positive yang konsisten baik dalam pelatihan maupun pengujian. Meskipun terdapat beberapa kesalahan klasifikasi, terutama pada prediksi sampel yang sebenarnya tidak berisiko (False Positive), model ini lebih andal dalam mendeteksi sampel yang berisiko (True Positive). Hal ini menunjukkan bahwa model MLP-ReLU memiliki potensi yang kuat untuk digunakan sebagai alat bantu dalam mendeteksi gejala risiko penyakit jantung, terutama dalam meminimalkan kesalahan identifikasi pada pasien yang berisiko.

Hasil pelatihan model MLP dengan fungsi aktivasi Tanh menunjukkan bahwa dari 439 sampel yang sebenarnya tidak berisiko (kelas 0), model berhasil mengklasifikasikan 378 sampel dengan benar (True Negative) dan salah mengklasifikasikan 61 sampel sebagai berisiko (False Positive). Sementara itu, dari 513 sampel yang sebenarnya berisiko (kelas 1), model mampu mengklasifikasikan 478 sampel dengan benar (True Positive) dan salah mengklasifikasikan 35 sampel sebagai tidak berisiko (False Negative). Hasil ini

menunjukkan bahwa model memiliki tingkat akurasi yang baik dalam mengklasifikasikan sampel pada kedua kelas, dengan jumlah kesalahan klasifikasi yang relatif rendah, terutama pada kelas yang berisiko. Hasil pengujian model MLP dengan fungsi aktivasi Tanh, model menunjukkan performa yang cukup baik, meskipun terdapat beberapa kesalahan dalam klasifikasi. Dari 122 sampel yang sebenarnya tidak berisiko (kelas 0), model mampu mengklasifikasikan 96 sampel dengan benar (True Negative) dan salah mengklasifikasikan 26 sampel sebagai berisiko (False Positive). Di sisi lain, dari 116 sampel yang sebenarnya berisiko (kelas 1), model berhasil mengklasifikasikan 95 sampel dengan benar (True Positive) namun salah mengklasifikasikan 21 sampel sebagai tidak berisiko (False Negative). Meskipun model cukup baik dalam mengidentifikasi sampel berisiko, terdapat sedikit peningkatan kesalahan klasifikasi dibandingkan dengan model berbasis ReLU, terutama pada sampel berisiko (kelas 1).

Berdasarkan hasil pelatihan dan pengujian model MLP dengan fungsi aktivasi Tanh, dapat disimpulkan bahwa model menunjukkan kemampuan yang baik dalam mendeteksi gejala risiko penyakit jantung. Model ini mampu mencapai tingkat akurasi yang tinggi dalam mengidentifikasi sampel berisiko (True Positive) dan tidak berisiko (True Negative), dengan jumlah kesalahan klasifikasi yang relatif rendah pada kedua kelas. Meskipun terdapat beberapa kesalahan dalam prediksi, terutama pada klasifikasi False Positive dan False Negative, model MLP-Tanh menunjukkan performa yang cukup solid dalam mengklasifikasikan risiko penyakit jantung. Hal ini menunjukkan bahwa model ini dapat menjadi alat yang efektif dalam mendeteksi gejala awal penyakit jantung, meskipun perlu perhatian ekstra terhadap pengurangan kesalahan klasifikasi pada sampel yang sebenarnya tidak berisiko atau berisiko tinggi.

KESIMPULAN

Berdasarkan hasil penelitian menggunakan model Multilayer Perceptron (MLP) dengan fungsi aktivasi ReLU dan Tanh untuk mendeteksi gejala risiko penyakit jantung, kedua model menunjukkan kemampuan yang baik dalam mengklasifikasikan sampel. Model MLP-ReLU memiliki keunggulan dalam mengidentifikasi sampel yang berisiko dengan tingkat True Positive yang stabil dan jumlah kesalahan klasifikasi yang relatif rendah, meskipun terdapat peningkatan pada False Positive dibandingkan dengan model MLP-Tanh. Sementara itu, model MLP-Tanh juga menunjukkan performa yang solid dengan akurasi tinggi pada kedua kelas, walaupun terdapat sedikit peningkatan pada False Negative. Dalam hal akurasi, precision, dan recall, MLP-ReLU mencatat nilai yang lebih tinggi (81,51%, 81,77%, dan 81,51%) dibandingkan dengan MLP-Tanh (80,25%, 80,32%, dan 80,25%). Hasil ini menegaskan bahwa penggunaan fungsi aktivasi ReLU lebih efektif dalam mengidentifikasi gejala risiko penyakit jantung pada dataset yang digunakan, menjadikannya pilihan yang lebih cocok untuk aplikasi deteksi dini yang membutuhkan keakuratan tinggi dalam pengklasifikasian risiko.

REFERENCES

- [1] S. I. Abda, A. Damayanti, and E. Winarko, "Detection of Heart Abnormalities Based On ECG Signal Characteristics using Multilayer Perceptron with Firefly Algorithm-Simulated Annealing," *Contemp. Math. Appl.*, vol. 3, no. 1, p. 45, 2021, doi: 10.20473/conmatha.v3i1.26941.
- [2] Y. Yuliani, "Algoritma Random Forest Untuk Prediksi Kelangsungan Hidup Pasien Gagal Jantung Menggunakan Seleksi Fitur Bestfirst," *Infotek J. Inform. dan Teknol.*, vol. 5, no. 2, pp. 298–306, 2022, doi: 10.29408/jit.v5i2.5896.
- [3] S. Likmi, "Comparative Analysis of Naive Bayes , K-Nearest Neighbors (KNN), and Support Vector Machine (SVM) Algorithms for Classification of Heart Disease Patients," *JOIN (Jurnal Online Inform.*, vol. 7, no. 2, pp. 219–225, 2022, doi: 10.15575/join.v7i2.919.
- [4] Y. Pamungkas, A. D. Wibawa, and M. D. Cahya, "Electronic Medical Record Data Analysis and Prediction of Stroke Disease Using Explainable Artificial Intelligence (XAI)," *Kinet. Game Technol. Inf. Syst. Comput. Network, Comput. Electron. Control*, vol. 4, no. 4, 2022, doi: 10.22219/kinetik.v7i4.1535.
- [5] A. K. Faeiq and M. M. Mijwil, "Prediction of of heart diseases utilising support vector machine and artificial neural network," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 26, no. 1, p. 374, Apr. 2022, doi: 10.11591/ijeecs.v26.i1.pp374-380.
- [6] K. Devendran, S. K. Thangarasu, P. Keerthika, R. Manjula Devi, and B. K. Ponnarasee, "Effective

- prediction on music therapy using hybrid SVM-ANN approach," *ITM Web Conf.*, vol. 37, p. 01014, 2021, doi: 10.1051/itmconf/20213701014.
- [7] A. Dutta, T. Batabyal, M. Basu, and S. T. Acton, "An efficient convolutional neural network for coronary heart disease prediction," *Expert Syst. Appl.*, vol. 159, 2020, doi: 10.1016/j.eswa.2020.113408.
- [8] D. Pardede, A. Ichsan, and S. Riyadi, "Enhancing Multi-Layer Perceptron Performance with K-Means Clustering," *J. Comput. Networks, Archit. High Perform. Comput.*, vol. 6, no. 1, pp. 461–466, Feb. 2024, doi: 10.47709/cnahpc.v6i1.3600.
- [9] D. Pardede, B. H. Hayadi, and Iskandar, "Multi-Layer Perceptron Literature Review How Well This Algorithm Performs," *J. ICT Apl. Syst.*, vol. 1, no. 1, pp. 23–35, Jun. 2022, doi: 10.56313/jictas.v1i1.127.
- [10] S. Mishra, H. K. Tripathy, P. K. Mallick, A. K. Bhoi, and P. Barsocchi, "Eaga-mlp—an enhanced and adaptive hybrid classification model for diabetes diagnosis," *Sensors (Switzerland)*, vol. 20, no. 14, pp. 1–34, 2020, doi: 10.3390/s20144036.
- [11] A. Al Bataineh and S. Manacek, "MLP-PSO Hybrid Algorithm for Heart Disease Prediction," *J. Pers. Med.*, vol. 12, no. 8, 2022, doi: 10.3390/jpm12081208.
- [12] Z. Guo, L. Xu, and N. Ali Asgharzadeholiaee, "A Homogeneous Ensemble Classifier for Breast Cancer Detection Using Parameters Tuning of MLP Neural Network," *Appl. Artif. Intell.*, vol. 36, no. 1, 2022, doi: 10.1080/08839514.2022.2031820.
- [13] S. Sharma, S. Sharma, and A. Anidhya, "Activation Functions in Neural Networks," *Int. J. Eng. Appl. Sci. Technol.*, vol. 4, no. 12, pp. 310–316, 2020, [Online]. Available: <https://ijeast.com/papers/310-316,Tesma412,IJEAST.pdf>
- [14] D. Pardede, I. Firmansyah, M. Handayani, M. Riandini, and R. Rosnelly, "Comparison Of Multilayer Perceptron's Activation And Optimization Functions In Classification Of Covid-19 Patients," *JURTEKSI (Jurnal Teknol. dan Sist. Informasi)*, vol. 8, no. 3, pp. 271–278, Aug. 2022, doi: 10.33330/jurteksiv8i3.1482.
- [15] A. Nguyen, K. Pham, D. Ngo, T. Ngo, and L. Pham, "An analysis of state-of-the-art activation functions for supervised deep neural network," *Proc. 2021 Int. Conf. Syst. Sci. Eng. ICSSE 2021*, pp. 215–220, 2021, doi: 10.1109/ICSSE52999.2021.9538437.
- [16] L. Nanni, S. Brahnem, M. Paci, and S. Ghidoni, "Comparison of Different Convolutional Neural Network Activation Functions and Methods for Building Ensembles for Small to Midsize Medical Data Sets," *Sensors*, vol. 22, no. 16, 2022, doi: 10.3390/s22166129.
- [17] L. Parisi, R. Ma, N. RaviChandran, and M. Lanzillotta, "hyper-sinh: An accurate and reliable function from shallow to deep learning in TensorFlow and Keras," *Mach. Learn. with Appl.*, vol. 6, no. July, p. 100112, 2021, doi: 10.1016/j.mlwa.2021.100112.
- [18] A. Mahgoub, "A Novel Approach to Heart Failure Prediction and Classification through Advanced Deep Learning Model," *World J. Cardiovasc. Dis.*, vol. 13, no. 09, pp. 586–604, 2023, doi: 10.4236/wjcd.2023.139052.
- [19] J. L. López and J. A. Vásquez-Coronel, "Congestive Heart Failure Category Classification Using Neural Networks in Short-Term Series," *Appl. Sci.*, vol. 13, no. 24, 2023, doi: 10.3390/app132413211.
- [20] N. Ahmed, F. Dilmaç, and A. Alpkocak, "Classification of biomedical texts for cardiovascular diseases with deep neural network using a weighted feature representation method," *Healthc.*, vol. 8, no. 4, pp. 1–15, 2020, doi: 10.3390/healthcare8040392.
- [21] Y. Pan, M. Fu, B. Cheng, X. Tao, and J. Guo, "Enhanced deep learning assisted convolutional neural network for heart disease prediction on the internet of medical things platform," *IEEE Access*, vol. 8, pp. 189503–189512, 2020, doi: 10.1109/ACCESS.2020.3026214.
- [22] Tb Ai Munandar, "Data Mining for Heart Disease Prediction Based on Echocardiogram and Electrocardiogram Data," *J. Online Inform.*, vol. 8, no. 1, pp. 91–98, 2023, doi: 10.15575/join.v8i1.1027.
- [23] C. Ordóñez, I. Fund, and L. Bellatreche, "Comparing Association Rules and Deep Neural Networks for Heart Disease Prediction," *Proc. - 2022 IEEE Int. Conf. Big Data, Big Data 2022*, pp. 4416–4424, 2022, doi: 10.1109/BigData55660.2022.10020522.
- [24] Maxwell, "Heart Disease Dataset," 2024. [Online]. Available: https://www.kaggle.com/datasets/mexwell/heart-disease-dataset?select=heart_statlog_cleveland_hungary_final.csv

- [25] D. Pardede and B. H. Hayadi, "Klasifikasi Sentimen Terhadap Gelaran MotoGP Mandalika 2022 Menggunakan Machine Learning," *J. Transform.*, vol. 20, no. 2, pp. 42–50, 2023.
- [26] I. Firmansyah and B. H. Hayadi, "Komparasi Fungsi Aktivasi Relu Dan Tanh Pada Multilayer Perceptron," *JIKO (Jurnal Inform. dan Komputer)*, vol. 6, no. 2, p. 200, 2022, doi: 10.26798/jiko.v6i2.600.
- [27] I. Firmansyah, J. T. Samudra, D. Pardede, and Z. Situmorang, "Comparison Of Random Forest And Logistic Regression In The Classification Of Covid-19 Sufferers Based On Symptoms," *J. Sci. Soc. Res.*, vol. 5, no. 3, p. 595, Oct. 2022, doi: 10.54314/jssr.v5i3.994.