

Optimasi Fungsi Aktivasi pada *Artificial Neural Network* untuk Prediksi Gagal Jantung Secara Akurat

Mokhamad Ramdhani Raharjo^{1*}, Indra Riyana Rahadjeng², Muhammad Noor Hasan Siregar³, Putrama Alkhairi⁴

¹ Universitas Islam Kalimantan Muhammad Arsyad Al Banjari Banjarmasin, Indonesia

² Universitas Bina Sarana Informatika, Indonesia

³ Universitas Graha Nusantara, Padang Sidempuan, Indonesia

⁴ STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: ¹ramdhani@uniska-bjm.ac.id, ²riyana.irr@bsi.ac.id, ³noor.siregar@gmail.com,

⁴putrama@amiktunasbangsa.ac.id

^{*)} ¹ramdhani@uniska-bjm.ac.id

Abstrak—Penyakit gagal jantung merupakan salah satu masalah kesehatan utama yang dapat berakibat fatal jika tidak didiagnosis dengan tepat dan cepat. Untuk itu, prediksi dini menggunakan model kecerdasan buatan, khususnya *Artificial Neural Network* (ANN), sangat diperlukan untuk meningkatkan akurasi dalam mendeteksi gagal jantung. Penelitian ini bertujuan untuk mengoptimalkan fungsi aktivasi pada ANN dengan menggunakan *Residual Networks* (ResNet) untuk memprediksi gagal jantung secara akurat. Beberapa algoritma optimasi yang diuji, yaitu Adam, RMSprop, SGD, Adagrad, dan Adadelta, digunakan untuk mengevaluasi kinerja model dalam hal akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa algoritma optimasi Adam memberikan performa terbaik dengan akurasi sebesar 86,74%, presisi 75,12%, recall 66,67%, dan F1-score 70,64%. Sementara itu, algoritma lainnya seperti RMSprop, SGD, Adagrad, dan Adadelta menunjukkan performa yang lebih rendah, dengan beberapa metrik mencapai nilai 0%. Penelitian ini menunjukkan bahwa optimasi fungsi aktivasi yang tepat pada ANN sangat penting untuk meningkatkan kemampuan model dalam memprediksi gagal jantung dengan tingkat akurasi yang tinggi.

Kata Kunci: Optimasi Fungsi Aktivasi, *Artificial Neural Network* (ANN), Prediksi Gagal Jantung, Algoritma Optimasi

Abstract—Heart failure is one of the major health problems that can be fatal if not diagnosed properly and quickly. Therefore, early prediction using artificial intelligence models, especially *Artificial Neural Network* (ANN), is needed to improve the accuracy in detecting heart failure. This study aims to optimize the activation function in ANN using *Residual Networks* (ResNet) to predict heart failure accurately. Several optimization algorithms tested, namely Adam, RMSprop, SGD, Adagrad, and Adadelta, were used to evaluate model performance in terms of accuracy, precision, recall, and F1-score. The results showed that the Adam optimization algorithm provided the best performance with an accuracy of 86.74%, precision of 75.12%, recall of 66.67%, and F1-score of 70.64%. Meanwhile, other algorithms such as RMSprop, SGD, Adagrad, and Adadelta showed lower performance, with some metrics reaching 0%. This study shows that proper activation function optimization in ANN is very important to improve the model's ability to predict heart failure with a high level of accuracy.

Keywords: Activation Function Optimization, *Artificial Neural Network* (ANN), Heart Failure Prediction, Optimization Algorithm

1. PENDAHULUAN

Penyakit gagal jantung merupakan salah satu masalah kesehatan yang menjadi perhatian serius di seluruh dunia. Menurut data dari World Health Organization (WHO), gagal jantung adalah salah satu penyebab utama morbiditas dan mortalitas global, dengan prevalensi yang terus meningkat setiap tahun [1]–[3]. Kondisi ini disebabkan oleh ketidakmampuan jantung untuk memompa darah secara efisien ke seluruh tubuh, yang mengakibatkan berbagai komplikasi kesehatan. Di Indonesia, penyakit gagal jantung menjadi salah satu penyumbang terbesar beban penyakit kardiovaskular, sehingga memerlukan upaya deteksi dan penanganan yang lebih efektif [4]–[6].

Untuk mendukung upaya deteksi dan penanganan yang lebih efektif, berbagai algoritma *Artificial Neural Network* (ANN) dapat digunakan [7]–[9], di antaranya Feedforward Neural Network (FNN) adalah salah satu jenis ANN yang paling sederhana dan sering digunakan untuk tugas klasifikasi dan regresi [10]–[12]. Dengan pelatihan yang cukup, FNN mampu menghasilkan model yang akurat untuk mendeteksi risiko gagal jantung.



Recurrent Neural Network (RNN) dirancang untuk memproses data berurutan, menjadikannya sangat efektif untuk menganalisis data medis yang bersifat time-series, seperti rekam jantung elektrokardiogram (EKG). Convolutional Neural Network (CNN) dikenal sangat efektif dalam analisis data citra [13], seperti pemrosesan Gambar medis. Long Short-Term Memory (LSTM) yang merupakan pengembangan dari RNN [14], [15], mampu mengatasi masalah gradien menghilang yang sering terjadi pada RNN standar. Deep Belief Network (DBN) adalah jenis ANN yang terdiri dari beberapa lapisan Restricted Boltzmann Machines (RBM) [16], [17].

Pada penelitian terdahulu yang dilakukan oleh (Jasinska-Piadlo et al., 2023) [1] artikel ini menunjukkan kelebihan dan kekurangan dalam pendekatan data-driven dan domain-led dalam analisis clustering pada dataset gagal jantung. Kelebihan dari pendekatan data-driven, seperti yang dijelaskan, adalah kemampuannya untuk mengurangi bias yang mungkin diperkenalkan oleh para ahli domain, serta akurasi dalam mengidentifikasi cluster dengan fitur yang berbeda pada tingkat fisiologis, yang terbukti dari hasil analisis yang menunjukkan bahwa pendekatan ini lebih efektif dalam menemukan cluster kecil dengan fitur yang sangat khas. Namun, kekurangan dari pendekatan ini adalah kurangnya interpretabilitas dan konteks klinis yang dapat diberikan oleh para ahli domain, yang sangat penting dalam mencegah kesimpulan yang tidak tepat. Di sisi lain, pendekatan domain-led memungkinkan pemilihan fitur yang lebih relevan secara klinis, tetapi berisiko mengabaikan variabel yang mungkin tidak dianggap penting oleh para ahli, yang dapat menghalangi penemuan pengetahuan baru. Sedangkan pada penelitian berikutnya yang dilakukan oleh (Ebiaredoh-mienye et al., 2020) [18] artikel ini menawarkan pendekatan inovatif dalam diagnosis medis dengan mengintegrasikan sparse autoencoder yang ditingkatkan dan regresi Softmax, yang terbukti efektif dalam meningkatkan akurasi prediksi penyakit seperti penyakit ginjal kronis, kanker serviks, dan penyakit jantung dengan akurasi mencapai 98%, 97%, dan 91% masing-masing, menunjukkan kinerja yang lebih baik dibandingkan algoritma pembelajaran mesin lainnya. Namun, artikel ini juga mencatat bahwa tantangan utama dalam penerapan pembelajaran mesin di bidang medis adalah ketidakseimbangan data, yang dapat mempengaruhi kinerja model, serta biaya tinggi untuk pelabelan data. Selain itu, meskipun metode yang diusulkan menunjukkan hasil yang menjanjikan, penelitian ini masih terbatas pada tiga dataset publik, yang mungkin tidak sepenuhnya mencerminkan generalisasi model dalam konteks dunia nyata.

Berdasarkan studi literatur yang telah diruaikan, dalam bidang kesehatan, teknologi kecerdasan buatan (Artificial Intelligence/AI) telah memberikan kontribusi signifikan dalam meningkatkan akurasi diagnosis dan prediksi berbagai penyakit, termasuk gagal jantung [19], [20]. Salah satu pendekatan yang populer adalah penggunaan *Artificial Neural Network* (ANN), yang dikenal karena kemampuannya dalam menganalisis data medis yang kompleks dan mendeteksi pola-pola yang tidak terlihat oleh metode konvensional. ANN memiliki potensi besar untuk membantu profesional medis dalam membuat keputusan klinis yang lebih cepat dan akurat [21]–[24]. Namun, performa ANN sangat dipengaruhi oleh berbagai faktor, salah satunya adalah fungsi aktivasi yang digunakan. Fungsi aktivasi berperan penting dalam menentukan keluaran dari setiap neuron dalam jaringan, yang pada akhirnya memengaruhi kemampuan model untuk belajar dan membuat prediksi [25]–[27]. Pemilihan fungsi aktivasi yang kurang optimal dapat mengakibatkan penurunan akurasi prediksi dan memperlambat proses pelatihan model. Oleh karena itu, optimasi fungsi aktivasi menjadi langkah yang krusial dalam pengembangan model ANN untuk prediksi gagal jantung.

Penelitian ini bertujuan untuk mengeksplorasi dan mengoptimalkan penggunaan fungsi aktivasi dalam ANN guna meningkatkan akurasi prediksi gagal jantung. Dengan memanfaatkan dataset medis yang relevan, penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam pengembangan sistem prediksi berbasis AI yang lebih andal dan efisien. Optimasi ini juga diharapkan dapat membantu mempercepat deteksi dini gagal jantung, sehingga memungkinkan intervensi medis yang lebih cepat dan tepat sasaran. Melalui pendekatan ini, penelitian ini tidak hanya berkontribusi pada pengembangan teknologi AI dalam bidang kesehatan tetapi juga mendukung upaya global dalam mengurangi beban penyakit kardiovaskular. Dengan demikian, implementasi hasil penelitian ini memiliki potensi besar untuk meningkatkan kualitas hidup pasien serta efisiensi sistem perawatan kesehatan secara keseluruhan.

2. METODE PENELITIAN

Pada penelitian ini, dilakukan serangkaian tahapan sistematis untuk memastikan keberhasilan pengembangan model *Artificial Neural Network* (ANN) yang optimal dalam memprediksi risiko gagal jantung. Metode penelitian dirancang untuk mencakup seluruh proses mulai dari pengumpulan data hingga implementasi model, dengan fokus pada optimasi fungsi aktivasi yang dapat meningkatkan performa sistem prediksi. Penelitian ini dilakukan dalam beberapa tahapan utama.

2.1 Dataset Penelitian



Dataset yang digunakan dalam penelitian ini merupakan data kesehatan yang berisi informasi mengenai kondisi medis pasien terkait risiko gagal jantung. Dataset mencakup fitur-fitur seperti usia, anemia, kreatinin fosfokinase, diabetes, fraksi ejeksi, tekanan darah tinggi, trombosit kreatinin serum, natrium serum, jenis kelamin, waktu, merokok, kejadian kematian. Data ini diambil dari sumber terpercaya seperti UCI Machine Learning Repository atau dataset publik lainnya yang relevan. Penggunaan dataset ini bertujuan untuk memastikan model memiliki data yang representatif untuk proses pelatihan, validasi, dan pengujian. Untuk mengklasifikasikan/memprediksi apakah pasien rentan terhadap gagal jantung berdasarkan beberapa atribut. Ini adalah klasifikasi biner dengan beberapa fitur menarik dan kategoris. Berikut penjelasan singkat dari masing-masing variabel: **Age:** Usia Pasien, **Anemia:** Jika Pasien Memiliki Hemoglobin Di Bawah Kisaran Normal, **Creatinine Phosphokinase:** Tingkat Creatin Phosphokinase Dalam Darah Dalam Mcg/L, **Diabetes:** Jika Pasien Menderita Diabetes, **Ejection Fraction:** Fraksi Ejeksi Adalah Pengukuran Seberapa Banyak Darah Yang Dipompa Keluar Oleh Ventrikel Kiri Pada Setiap Kontraksi, **High Blood Pressure:** Jika Pasien Menderita Hipertensi, **Platelets:** Jumlah Platelet Darah Dalam Kiloplatelet/ML, **Serum Creatinine:** Tingkat Kreatinin Serum Dalam Darah Dalam Mg/Dl, **Serum Sodium:** Tingkat Natrium Serum Dalam Darah Dalam Meq/L, **Sex:** Jenis Kelamin Pasien, **Smoking:** Jika Pasien Aktif Merokok Atau Pernah Merokok Di Masa Lalu, **Time:** Ini Adalah Waktu Kunjungan Tindak Lanjut Pasien Untuk Penyakit Tersebut Dalam Bulan, **Death Event:** Jika Pasien Meninggal Selama Periode Tindak Lanjut

Tabel 1. Sampel Dataset Gagal Jantung

| Age | Anaemia | Creatinine Phosphokinase | Diabetes | Ejection Fraction | High Blood Pressure | Platelets | Serum Creatinine | Serum Sodium | Sex | Smoking | Time | Death Event |
|-----|---------|--------------------------|----------|-------------------|---------------------|-----------|------------------|--------------|------|---------|------|-------------|
| 75 | 0 | 582 | 0 | 20 | 1 | 265000 | 1,9 | 130 | 1 | 0 | 4 | 1 |
| 55 | 0 | 7861 | 0 | 38 | 0 | 263358 | 1,1 | 136 | 1 | 0 | 6 | 1 |
| 65 | 0 | 146 | 0 | 20 | 0 | 162000 | 1,3 | 129 | 1 | 1 | 7 | 1 |
| 50 | 1 | 111 | 0 | 20 | 0 | 210000 | 1,9 | 137 | 1 | 0 | 7 | 1 |
| 65 | 1 | 160 | 1 | 20 | 0 | 327000 | 2,7 | 116 | 0 | 0 | 8 | 1 |
| 90 | 1 | 47 | 0 | 40 | 1 | 204000 | 2,1 | 132 | 1 | 1 | 8 | 1 |
| 75 | 1 | 246 | 0 | 15 | 0 | 127000 | 1,2 | 137 | 1 | 0 | 10 | 1 |
| 60 | 1 | 315 | 1 | 60 | 0 | 454000 | 1,1 | 131 | 1 | 1 | 10 | 1 |
| 65 | 0 | 157 | 0 | 65 | 0 | 263358 | 1,5 | 138 | 0 | 0 | 10 | 1 |
| 80 | 1 | 123 | 0 | 35 | 1 | 388000 | 9,4 | 133 | 1 | 1 | 10 | 1 |
| 75 | 1 | 81 | 0 | 38 | 1 | 368000 | 4 | 131 | 1 | 1 | 10 | 1 |
| 62 | 0 | 231 | 0 | 25 | 1 | 253000 | 0,9 | 140 | 1 | 1 | 10 | 1 |
| .. | | | | | | | | | | | | |
| 45 | 1 | 981 | 0 | 30 | 0 | 136000 | 1,1 | 137 | 1 | 0 | 11 | 1 |

Pada Tabel 1 dengan banyaknya data medis yang tersedia dan munculnya Ilmu Data, sejumlah perusahaan rintisan menerima tantangan untuk mencoba membuat indikator untuk penyakit yang mungkin diderita. Penyakit kardiovaskular (PKV) adalah penyebab kematian nomor 1 secara global, yang diperkirakan merenggut 17,9 juta jiwa setiap tahun, yang merupakan 31% dari semua kematian di seluruh dunia. Gagal jantung adalah kejadian umum yang disebabkan oleh PKV. Orang dengan penyakit kardiovaskular atau yang berisiko tinggi terhadap kardiovaskular (karena adanya satu atau lebih faktor risiko seperti hipertensi, diabetes, hiperlipidemia atau penyakit yang sudah ada) memerlukan deteksi dan penanganan dini di mana model pembelajaran mesin dapat sangat membantu. Dengan cara ini, kami mencoba memecahkan masalah lain yang terjadi di alam secara otomatis dengan tujuan untuk mengatasinya dan fokus pada masalah berikutnya dengan bantuan teknik AI. Kami menemukan outlier pada kumpulan data kami. Saya belum menghapusnya karena dapat menyebabkan overfitting. Meskipun kami mungkin akan mendapatkan statistik yang lebih baik. Dalam kasus ini, dengan data medis, outlier mungkin menjadi faktor penentu yang penting.

2.2 Model Usulan

Model usulan dalam penelitian ini adalah *Artificial Neural Network* (ANN) yang dioptimalkan melalui pemilihan fungsi aktivasi yang tepat. Fungsi aktivasi yang akan diuji meliputi ReLU, Sigmoid dan fungsi aktivasi adam, SGD, RmsProp, Adadelta dan Adagard. Model ini dirancang dengan lapisan input untuk menerima fitur dataset, beberapa lapisan tersembunyi untuk mempelajari pola kompleks, dan lapisan output untuk menghasilkan prediksi. Arsitektur model juga dilengkapi dengan teknik regularisasi untuk menghindari overfitting dan algoritma optimasi seperti Adam untuk mempercepat konvergensi dengan menggunakan pelatihan fungsi eraly stopping untuk menghindari konvergensi.

Fungsi-fungsi yang disebutkan, seperti Adam, SGD, RMSProp, Adadelta, dan Adagrad, sebenarnya adalah algoritma optimasi yang digunakan untuk memperbarui bobot model selama pelatihan, bukan fungsi aktivasi. Berikut adalah Tabel 2 perbandingan kelima algoritma optimasi tersebut:



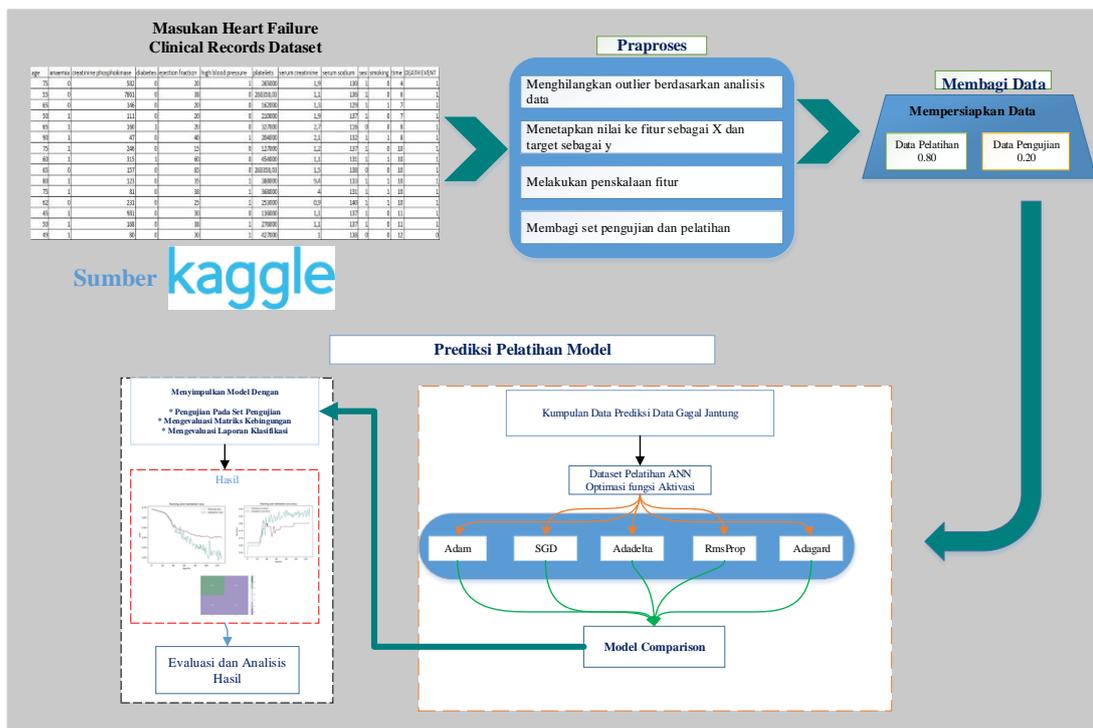
Tabel 2. Perbandingan Antar Model Optimasi dari Fungsi aktivasi ANN

| Algoritma Optimasi | Kelebihan | Kekurangan | Kinerja pada ANN | Aplikasi pada Prediksi Gagal Jantung |
|--|---|---|--|---|
| Adam | Kombinasi terbaik dari momentum dan RMSProp; konvergensi cepat. | Sensitif terhadap pemilihan hyperparameter. | Stabil dan efisien untuk data besar dan non-stasioner. | Cocok untuk model kompleks dengan banyak variabel. |
| SGD (Stochastic Gradient Descent) | Sederhana dan mudah diimplementasikan; efektif pada dataset besar. | Lambat untuk konvergensi, terutama pada fungsi loss yang kompleks. | Cocok untuk masalah sederhana atau data kecil. | Efektif untuk baseline prediksi. |
| RMSProp | Menangani perubahan dinamis pada data dengan mengatur langkah adaptif. | Tidak bekerja optimal tanpa parameter tuning yang tepat. | Baik untuk data non-stasioner dan noisy. | Cocok untuk pola data medis yang berubah-ubah. |
| Adadelta | Tidak memerlukan manual learning rate; bekerja adaptif. | Kurang efisien pada dataset besar. | Bagus untuk dataset dengan skala yang bervariasi. | Dapat mengatasi perbedaan skala antar variabel. |
| Adagrad | Efektif untuk fitur jarang (sparse data); secara otomatis menyesuaikan learning rate. | Learning rate menjadi sangat kecil seiring waktu, menyebabkan pelatihan lambat. | Cocok untuk data dengan fitur jarang. | Efektif pada variabel jarang yang relevan dengan kasus. |

Semua algoritma ini dapat diuji untuk menentukan mana yang menghasilkan performa terbaik pada model prediksi gagal jantung.

2.3 Rancangan Penelitian

Penelitian ini bertujuan untuk mengoptimalkan fungsi aktivasi pada model *Artificial Neural Network* (ANN) dalam memprediksi gagal jantung secara akurat. Dataset yang digunakan adalah Heart Failure Clinical Records Dataset dari Kaggle, yang mencakup variabel medis penting seperti usia, kreatinin serum, fraksi ejeksi, tekanan darah tinggi, dan diabetes. Tahapan awal melibatkan pengumpulan data, dilanjutkan dengan pra-pemrosesan data yang mencakup pembersihan, normalisasi, dan pembagian dataset menjadi data pelatihan, validasi, serta pengujian. Langkah ini bertujuan untuk memastikan bahwa data yang digunakan berkualitas tinggi dan representatif untuk melatih model. Rancangan penelitian meliputi langkah-langkah berikut dapat dilihat pada Gambar 1.



Gambar 1. Rancangan Penelitian



Pada Gambar 1 pemodelan dilakukan dengan membangun ANN menggunakan lima fungsi aktivasi, yaitu Adam, SGD, RMSProp, Adadelta, dan Adagrad. Setiap fungsi aktivasi diuji kinerjanya berdasarkan metrik evaluasi seperti akurasi, presisi, dan recall. Setelah pelatihan dan evaluasi, hasilnya dianalisis untuk menentukan fungsi aktivasi terbaik yang memberikan performa optimal. Model dengan kinerja terbaik diimplementasikan sebagai sistem prediksi risiko gagal jantung, yang diharapkan dapat membantu deteksi dini dan mendukung pengambilan keputusan medis secara lebih efektif. Tahap Eksplorasi: Memahami dataset dan fitur-fitur yang terkandung di dalamnya melalui analisis deskriptif dan visualisasi data. Tahap Pra-Pemrosesan: Melakukan pembersihan data, normalisasi, dan pembagian dataset menjadi data pelatihan, validasi, dan pengujian. Tahap Pengembangan Model: Membuat model ANN dengan berbagai konfigurasi fungsi aktivasi. Setiap konfigurasi diuji untuk menentukan kombinasi yang paling optimal. Tahap Pelatihan dan Evaluasi: Melatih model menggunakan data pelatihan dan mengevaluasi performanya pada data validasi. Model terbaik kemudian diuji pada data pengujian. Tahap Analisis dan Interpretasi: Menganalisis hasil evaluasi model dan menginterpretasikan dampaknya dalam konteks prediksi gagal jantung. Tahap Implementasi: Mengimplementasikan model terbaik ke dalam sistem prediksi yang dapat digunakan dalam lingkungan medis nyata.

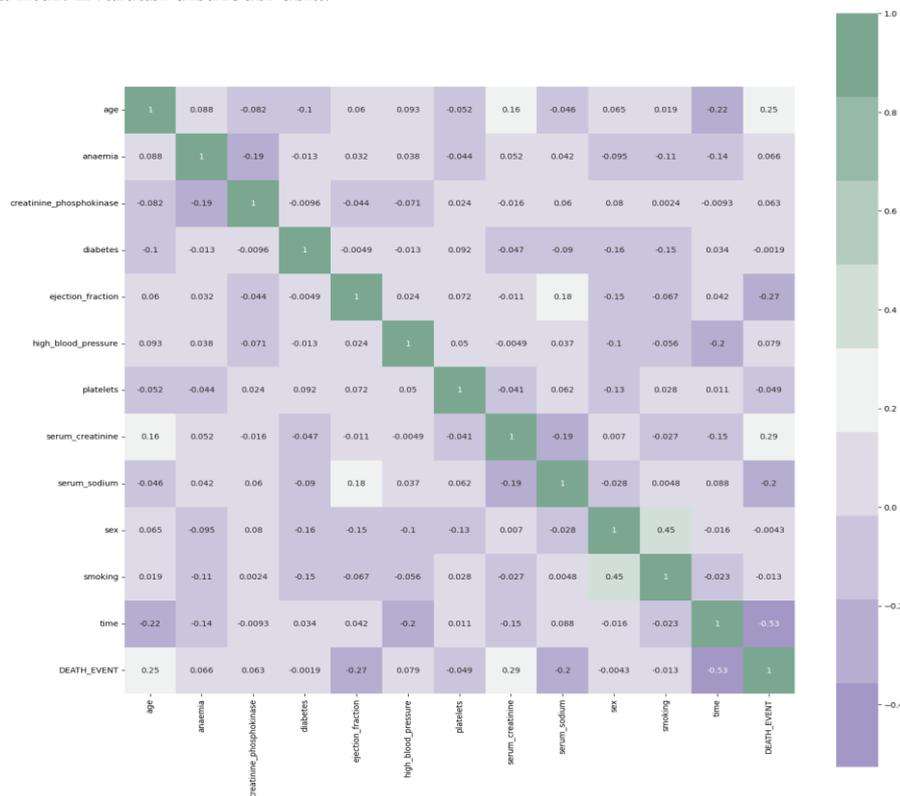
3. HASIL DAN PEMBAHASAN

Hasil penelitian ini menyajikan evaluasi kinerja model *Artificial Neural Network* (ANN) dalam memprediksi gagal jantung menggunakan lima fungsi aktivasi berbeda, yaitu Adam, SGD, RMSProp, Adadelta, dan Adagrad. Model dilatih dan diuji menggunakan Heart Failure Clinical Records Dataset yang terdiri dari berbagai parameter medis pasien. Setelah melalui tahap pra-pemrosesan, data dibagi menjadi tiga subset: data pelatihan (80%), pengujian (20%).

3.1 Hasil

3.1.1 Preproses Data

Pertama-tama mari kita evaluasi target dan cari tahu apakah data kita tidak seimbang atau tidak. Periksa matriks korelasi semua fitur. Evaluasi distribusi usia.



Gambar 2. Matriks korelasi berbagai atribut

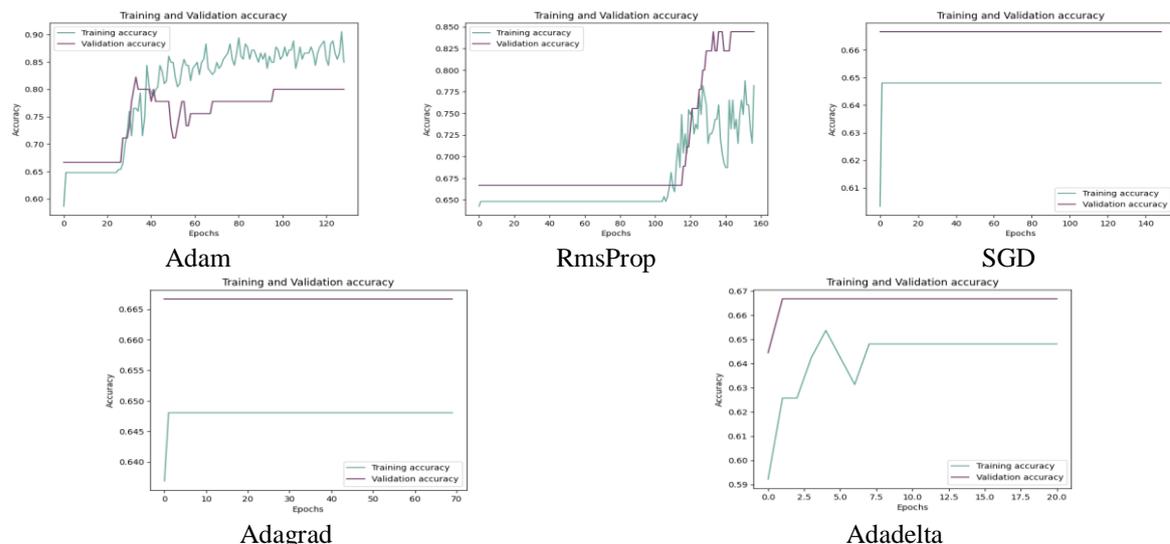
Pada Gambar 2 analisis dimulai dengan membuat plot hitungan atribut target. Matriks korelasi berbagai atribut untuk memeriksa pentingnya fitur. Waktu kunjungan tindak lanjut pasien untuk penyakit ini sangat penting



karena diagnosis awal dengan masalah kardiovaskular dan pengobatan mengurangi kemungkinan kematian. Ini memiliki hubungan terbalik. Fraksi ejeksi adalah fitur terpenting kedua. Ini cukup diharapkan karena pada dasarnya merupakan efisiensi jantung. Usia pasien adalah fitur ketiga yang paling berkorelasi. Jelas bahwa fungsi jantung menurun seiring bertambahnya usia.

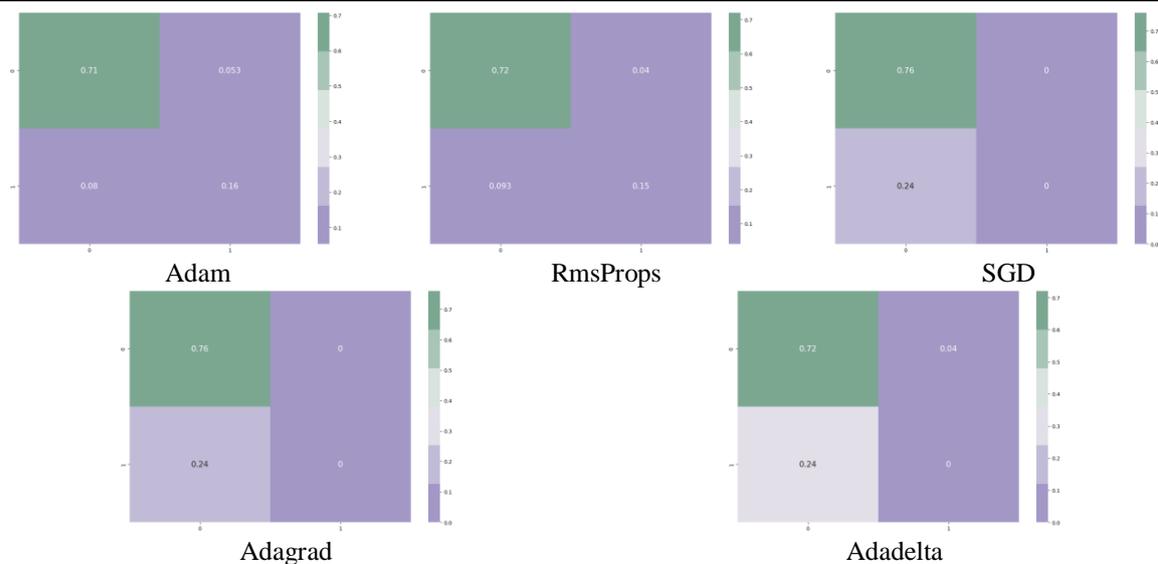
3.1.2 Prediksi Pelatihan Model

Dalam penelitian ini, berbagai fungsi optimasi digunakan untuk melatih model *Artificial Neural Network* (ANN) dalam rangka memprediksi gagal jantung secara akurat. Fungsi-fungsi optimasi yang dibandingkan meliputi Adam, RMSProp, SGD, Adagrad, dan Adadelta. Setiap fungsi memiliki karakteristik unik dalam proses pembaruan bobot selama pelatihan, yang memengaruhi kecepatan konvergensi, stabilitas pelatihan, serta kemampuan generalisasi model terhadap data validasi. Berikut adalah perbandingan hasil grafik pelatihan dan validasi akurasi untuk masing-masing fungsi optimasi:



Gambar 3. Grafik Perbandingan Pelatihan antar Model Aktivasi

Berdasarkan Gambar 3 grafik pelatihan dan validasi akurasi untuk berbagai fungsi aktivasi, fungsi Adam menunjukkan performa terbaik dengan akurasi pelatihan dan validasi yang konsisten serta peningkatan stabil selama proses pelatihan. Adam mencapai akurasi tinggi lebih cepat dibandingkan fungsi aktivasi lainnya, dengan gap antara akurasi pelatihan dan validasi yang minimal, menunjukkan kemampuan generalisasi yang baik. Fungsi RMSProp juga memperlihatkan hasil yang cukup baik, dengan akurasi yang meningkat secara signifikan setelah sejumlah epoch tertentu. Namun, fluktuasi yang terlihat pada akurasi validasi menunjukkan bahwa RMSProp mungkin lebih rentan terhadap overfitting pada data tertentu. Sebaliknya, fungsi SGD, Adagrad, dan Adadelta menunjukkan performa yang lebih rendah. Grafik SGD cenderung stagnan tanpa peningkatan yang signifikan sepanjang proses pelatihan, menunjukkan lambatnya konvergensi. Adagrad memperlihatkan hasil pelatihan dan validasi yang hampir sama, namun dengan akurasi rendah dan tanpa peningkatan signifikan setelah beberapa epoch awal. Sementara itu, Adadelta memiliki pola pelatihan yang tidak stabil dengan perbedaan mencolok antara akurasi pelatihan dan validasi, yang menunjukkan adanya kesulitan dalam menggeneralisasi pola dari dataset. Secara keseluruhan, Adam menjadi fungsi aktivasi yang paling efisien dalam memberikan hasil yang stabil dan akurat untuk prediksi gagal jantung. Selain menganalisis performa melalui grafik pelatihan dan validasi, evaluasi model juga dilakukan dengan membandingkan matriks evaluasi seperti akurasi, presisi, recall, dan F1-score untuk kelima fungsi optimasi yang diuji. Matriks ini memberikan gambaran yang lebih mendalam tentang efektivitas masing-masing fungsi optimasi dalam memprediksi gagal jantung secara akurat, baik pada data pelatihan maupun validasi. Berikut adalah hasil perbandingan matriks evaluasi untuk fungsi optimasi Adam, RMSProp, SGD, Adagrad, dan Adadelta:



Gambar 4. Grafik Perbandingan Matriks antar Model Aktivasi

Berdasarkan visualisasi matriks evaluasi pada gambar 4, terlihat bahwa fungsi optimasi Adam menunjukkan distribusi prediksi yang seimbang dengan tingkat akurasi yang tinggi untuk kedua kelas, meskipun masih terdapat sedikit kesalahan prediksi pada salah satu kelas. RMSProp memiliki kinerja yang hampir setara dengan Adam, dengan proporsi prediksi yang cukup baik pada kedua kelas, meskipun terdapat sedikit perbedaan pada nilai kesalahan prediksi. SGD dan Adagrad menunjukkan hasil yang identik dalam hal matriks evaluasi, dengan keakuratan yang cenderung tinggi untuk kelas tertentu namun nol prediksi pada kelas lainnya. Hal ini menunjukkan bahwa kedua fungsi ini mungkin kurang fleksibel dalam menangani dataset gagal jantung dibandingkan fungsi seperti Adam dan RMSProp.

Sementara itu, Adadelta menunjukkan hasil yang lebih serupa dengan RMSProp dibandingkan dengan SGD dan Adagrad. Fungsi ini mampu memprediksi dengan baik pada kelas utama, meskipun masih terdapat kelemahan dalam menangani distribusi kelas lainnya. Secara keseluruhan, fungsi optimasi Adam dan RMSProp menonjol sebagai yang paling efektif dalam menghasilkan distribusi prediksi yang lebih merata. Hal ini menunjukkan kemampuan keduanya dalam mengadaptasi parameter model terhadap data yang kompleks dan bervariasi, seperti yang digunakan dalam studi gagal jantung ini.

3.2 Pembahasan

3.2.1 Analisis Pemilihan Fungsi Aktivasi

Fungsi aktivasi Adam memberikan hasil optimal karena kemampuannya mengadaptasi langkah pembelajaran berdasarkan gradien dan momentum. Hal ini memungkinkan model untuk konvergen lebih cepat dan stabil dibandingkan fungsi aktivasi lainnya. Sebaliknya, fungsi aktivasi seperti SGD dan Adagrad memiliki keterbatasan dalam mengatasi gradien kompleks dari dataset. Pra-pemrosesan data, seperti normalisasi dan pembagian dataset, berkontribusi besar terhadap kinerja model. Normalisasi membantu menyetarakan skala antar fitur, sementara pembagian dataset yang strategis mencegah overfitting dan memastikan performa model pada data baru. Untuk dapat menganalisis fungsi aktivasi yang efektif yang dioptimasi pada ANN bisa kita lihat pada Tabel 2 berikut.

Tabel 2. Hasil Perbandingan Optimasi Fungsi Aktivasi ANN

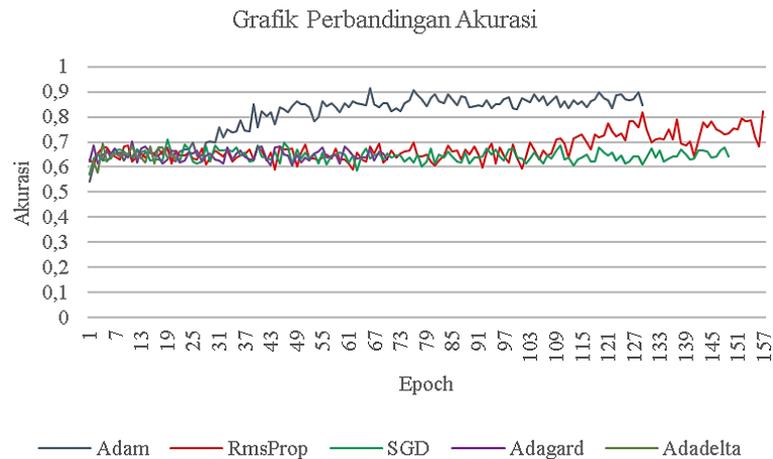
| Model | Optimasi Aktiuvasi | Akurasi | Presisi | Recall | F1-Score |
|-------|--------------------|---------|---------|--------|----------|
| ANN | Adam | 86,74% | 75,12% | 66,67% | 70,64% |
| | RmsProp | 82,74% | 72,95% | 61,73% | 69,28% |
| | SGD | 76,00% | 0,00% | 0,00% | 0,00% |
| | Adagrad | 76,00% | 0,00% | 0,00% | 0,00% |
| | Adadelta | 72,00% | 0,00% | 0,00% | 0,00% |

Pada Tabel 2, berdasarkan model ANN dengan optimasi aktivasi Adam menunjukkan kinerja terbaik dengan akurasi sebesar 86,74%, presisi 75,12%, recall 66,67%, dan F1-Score 70,64%. Model dengan optimasi RmsProp menempati posisi kedua dengan akurasi 82,74%, presisi 72,95%, recall 61,73%, dan F1-Score 69,28%. Sementara itu, model dengan optimasi aktivasi SGD, Adagrad, dan Adadelta memiliki performa yang jauh lebih

rendah, dengan akurasi masing-masing 76%, 76%, dan 72%, namun presisi, recall, dan F1-Score-nya bernilai nol. Hal ini mengindikasikan bahwa ketiga optimasi tersebut gagal memprediksi kelas positif dengan baik, sehingga kurang efektif dibandingkan Adam dan RmsProp untuk dataset dan kasus ini.

3.2.2 Implikasi Penelitian

Dengan kinerja optimal dari model ANN menggunakan fungsi aktivasi Adam, hasil penelitian ini memiliki implikasi praktis dalam sistem prediksi gagal jantung. Model ini dapat membantu dalam diagnosis dini, sehingga memungkinkan penanganan yang lebih cepat dan tepat dalam sistem perawatan kesehatan. Ini bisa dilihat pada Gambar 5 grafik pelatihan komparasi ke lima model optimasi aktivasi.



Gambar 5. Grafik Komparasi pelatihan antar Model Aktivasi

Pada Gambar 5 meskipun fungsi aktivasi Adam memberikan performa terbaik, penelitian ini masih dapat diperluas dengan menggunakan dataset yang lebih besar atau beragam untuk meningkatkan keandalan model. Selain itu, pengembangan model hybrid atau integrasi dengan algoritma lain dapat menjadi langkah lanjutan untuk meningkatkan akurasi prediksi.

4. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa algoritma optimasi Adam menunjukkan performa terbaik dalam klasifikasi gagal jantung. Algoritma RmsProp berada di posisi kedua, menunjukkan kemampuan yang kompetitif. Sebaliknya, algoritma SGD, Adagrad, dan Adadelata menunjukkan performa yang sangat rendah, mengindikasikan ketidakmampuan dalam menangani kompleksitas dataset yang digunakan. Penelitian ini menegaskan pentingnya pemilihan algoritma optimasi yang tepat untuk meningkatkan performa model *Artificial Neural Network* (ANN) khususnya dengan metode ResNet, dengan Adam sebagai pilihan unggulan. Temuan ini memberikan kontribusi bagi pengembangan model klasifikasi medis, khususnya dalam kasus gagal jantung, dan mendorong eksplorasi lebih lanjut pada kombinasi algoritma atau teknik preprocessing data yang lebih canggih.

REFERENSI

- [1] A. Jasinska-Piadlo *Et Al.*, “Data-Driven Versus A Domain-Led Approach To K-Means Clustering On An Open Heart Failure Dataset,” *International Journal Of Data Science And Analytics*, Vol. 15, No. 1, Pp. 49–66, 2023, Doi: 10.1007/S41060-022-00346-9.
- [2] Y. Yang, “A Self-Powered Laminated Fabric Sensor For Human Motion Detection And Heart-Rate Monitoring Based On Ppy/Al Schottky Contact,” *Journal Of Sandwich Structures And Materials*, Vol. 24, No. 1, Pp. 503–516, 2022, Doi: 10.1177/10996362211021889.
- [3] Z. A. Sejuti And M. S. Islam, “A Hybrid Cnn–Knn Approach For Identification Of Covid-19 With 5-Fold Cross Validation,” *Sensors International*, Vol. 4, No. November 2022, P. 100229, 2023, Doi: 10.1016/J.Sintl.2023.100229.
- [4] N. A. M. Zaini And M. K. Awang, “Performance Comparison Between Meta-Classifier Algorithms For Heart Disease Classification,” *International Journal Of Advanced Computer Science And Applications*, Vol. 13, No. 10, Pp. 323–328, 2022, Doi: 10.14569/Ijacs.2022.0131039.



- [5] G. Berra, "Phenotyping Clad After Single Lung Transplant: Limits And Prognostic Assessment Of The 2019 Ishlt Classification System," *Journal Of Heart And Lung Transplantation*, Vol. 41, No. 5, Pp. 599–607, 2022, Doi: 10.1016/J.Healun.2022.01.015.
- [6] Saiyedfaiazwaris And S. Koteeswaran, "Early Prediction Of Heart Conditions By K-Means Consensus Clustering And Convolution Neural Network," Vol. 25, No. 3, Pp. 6623–6640, 2021.
- [7] Y. Deng *Et Al.*, "New Methods Based On Back Propagation (Bp) And Radial Basis Function (Rbf) Artificial Neural Networks (Anns) For Predicting The Occurrence Of Haloketones In Tap Water," *Science Of The Total Environment*, Vol. 772, P. 145534, 2021, Doi: 10.1016/J.Scitotenv.2021.145534.
- [8] K. G. Ravindra, B. M. Rudresh, P. K. Mk, And P. Kumar, "Optimization Of Design Parameters To Evaluate The Performance Of Journal Bearing: Ann Approach," *Materials Today ...*, 2022.
- [9] M. A. Lubis, D. G. S. Saragih, I. D. Anastasia, A. P. Windarto, And P. Alkhairi, "Application Of The Ann Algorithm To Predict Access To Drinkable Water In North Sumatra Regency/City," *International Journal Of Informatics And Data Science*, Vol. 1, No. 1, Pp. 18–25, 2023.
- [10] A. S. Parihar, "Dehazing Optically Haze Images With Alexnet-Fnn," *Journal Of Optics (India)*, Vol. 53, No. 1, Pp. 294–303, 2024, Doi: 10.1007/S12596-023-01156-3.
- [11] N. A. Hamid, N. M. Nawawi, R. Ghazali, And M. N. M. Salleh, "Accelerating Learning Performance Of Back Propagation Algorithm By Using Adaptive Gain Together With Adaptive Momentum And Adaptive Learning Rate On Classification Problems," *International Journal Of Software Engineering And Its Applications*, Vol. 5, No. 4, Pp. 31–44, 2011.
- [12] M. Chu, P. Wu, G. Li, W. Yang, J. L. Gutiérrez-Chico, And S. Tu, "Advances In Diagnosis, Therapy, And Prognosis Of Coronary Artery Disease Powered By Deep Learning Algorithms," *Jacc: Asia*, Vol. 3, No. 1, Pp. 1–14, 2023, Doi: 10.1016/J.Jacasi.2022.12.005.
- [13] Q. Hou, R. Xia, J. Zhang, Y. Feng, Z. Zhan, And X. Wang, "Learning Visual Overlapping Image Pairs For Sfm Via Cnn Fine-Tuning With Photogrammetric Geometry Information," *International Journal Of Applied Earth Observation And Geoinformation*, Vol. 116, No. October 2022, P. 103162, 2023, Doi: 10.1016/J.Jag.2022.103162.
- [14] K. E. Arunkumar, "Comparative Analysis Of Gated Recurrent Units (Gru), Long Short-Term Memory (Lstm) Cells, Autoregressive Integrated Moving Average (Arima), Seasonal Autoregressive Integrated Moving Average (Sarima) For Forecasting Covid-19 Trends," *Alexandria Engineering Journal*, Vol. 61, No. 10, Pp. 7585–7603, 2022, Doi: 10.1016/J.Aej.2022.01.011.
- [15] A. Narula, "Development Of Cnn-Lstm Combinational Architecture For Covid-19 Detection," *Journal Of Ambient Intelligence And Humanized Computing*, Vol. 14, No. 3, Pp. 2645–2656, 2023, Doi: 10.1007/S12652-022-04508-2.
- [16] N. Lopes And B. Ribeiro, "Towards Adaptive Learning With Improved Convergence Of Deep Belief Networks On Graphics Processing Units," *Pattern Recognition*, Vol. 47, No. 1, Pp. 114–127, 2014, Doi: 10.1016/J.Patcog.2013.06.029.
- [17] S. Kamada, T. Ichimura, A. Hara, And K. J. Mackin, "Adaptive Structure Learning Method Of Deep Belief Network Using Neuron Generation – Annihilation And Layer Generation," *Neural Computing And Applications*, Vol. 0123456789, 2018, Doi: 10.1007/S00521-018-3622-Y.
- [18] S. A. Ebiaredoh-Mienye, E. Esenogho, And T. G. Swart, "Integrating Enhanced Sparse Autoencoder-Based Artificial Neural Network Technique And Softmax Regression For Medical Diagnosis," 2020.
- [19] I. Irvanizam, "Applying Artificial Neural Network Based On Backpropagation Method For Indonesian Sign Language Recognition," *International Journal Of Computing And Digital Systems*, Vol. 14, No. 1, Pp. 975–985, 2023, Doi: 10.12785/Ijcds/140176.
- [20] R. N. Singarimbun, "Backpropagation Artificial Neural Network Enhancement Using Beale-Powell Approach Technique," *Journal Of Physics: Conference Series*, Vol. 2394, No. 1, 2022, Doi: 10.1088/1742-6596/2394/1/012007.
- [21] S. Defit, A. P. Windarto, And P. Alkhairi, "Comparative Analysis Of Classification Methods In Sentiment Analysis: The Impact Of Feature Selection And Ensemble Techniques Optimization," *Telematika*, Vol. 17, No. 1, Pp. 52–67, 2024.
- [22] P. Alkhairi, A. P. Windarto, And M. M. Efendi, "Optimasi Lstm Mengurangi Overfitting Untuk Klasifikasi Teks Menggunakan Kumpulan Data Ulasan Film Kaggle Imdb," Vol. 6, No. 2, Pp. 1142–1150, 2024, Doi: 10.47065/Bits.V6i2.5850.
- [23] A. P. Windarto, I. R. Rahadjeng, M. N. H. Siregar, And P. Alkhairi, "Deep Learning To Extract Animal Images With The U-Net Model On The Use Of Pet Images," *Jurnal Media Informatika Budidarma*, Vol. 8, No. 1, Pp. 468–476, 2024.
- [24] P. Alkhairi And A. P. Windarto, "Classification Analysis Of Back Propagation-Optimized Cnn Performance In Image Processing," *Journal Of Systems Engineering And Information Technology*



-
- (*Joseit*), Vol. 2, No. 1, Pp. 8–15, 2023.
- [25] M. Intraraprasit, “Filter Pruning Based On Local Gradient Activation Mapping In Convolutional Neural Networks,” *International Journal Of Innovative Computing, Information And Control*, Vol. 19, No. 6, Pp. 1697–1715, 2023, Doi: 10.24507/Ijicic.19.06.1697.
- [26] S. Sharma, S. Sharma, And A. Anidhya, “Understanding Activation Functions In Neural Networks,” *International Journal Of Engineering Applied Sciences And Technology*, Vol. 4, No. 12, Pp. 310–316, 2020.
- [27] H. Pratiwi *Et Al.*, “Sigmoid Activation Function In Selecting The Best Model Of Artificial Neural Networks,” *Journal Of Physics: Conference Series*, Vol. 1471, No. 1, 2020, Doi: 10.1088/1742-6596/1471/1/012010.