

Prediksi Gagal Jantung Berbasis Deep Learning dengan Algoritma Long Short Term Memory

Ibnu Atho'illah¹, Annisa Fitri Madani², Ni Nyoman Emang Smrti³, I Putu Gd. Sukenada Andisana⁴

^{1,2,3} Teknik Informatika, STMIK Bandung Bali, ⁴Sistem Informasi, STMIK Bandung Bali
Jl. Bypass Ngurah Rai No.21, Kedonganan, Kabupaten Badung, Bali 80361 - Indonesia

¹ibnu.athoillah@gmail.com (penulis korespondensi)

²nnsmadani@gmail.com

³smrti@yacanet.com

⁴sukenada.andisana@gmail.com

Intisari— Penyakit gagal jantung merupakan salah satu penyebab kematian tertinggi di dunia. Deteksi dini dan analisis yang akurat sangat penting untuk penanganan yang tepat. Penelitian ini mengusulkan penggunaan algoritma Long Short-Term Memory (LSTM) untuk menganalisis dan memprediksi perkembangan penyakit gagal jantung berdasarkan data medis pasien. Model LSTM yang dikembangkan menggunakan platform Python dengan library TensorFlow dan Keras, serta dataset "Heart Failure Prediction" dari Kaggle.com. Hasil penelitian menunjukkan bahwa model LSTM dengan rasio data pelatihan dan pengujian 70:30 (Model B) mencapai performa terbaik dengan akurasi sebesar 0.869, presisi 0.869, recall 0.869, dan F1-score 0.869. Model ini menunjukkan kemampuan yang konsisten dalam mengidentifikasi kasus positif dan negatif gagal jantung, serta efektif dalam mengurangi overfitting. Secara keseluruhan, penelitian ini memberikan kontribusi dalam pengembangan metode prediksi penyakit gagal jantung yang lebih akurat dan efisien.

Kata kunci— Long Short Term Memory, Gagal Jantung, Confusion Matrix, Akurasi, TensorFlow.

Abstract— Heart failure is one of the leading causes of death in the world. Early detection and accurate analysis are essential for proper treatment. This study proposes the use of Long Short-Term Memory (LSTM) algorithm to analyse and predict the progression of heart failure disease based on patient medical data. The LSTM model developed uses the Python platform with TensorFlow and Keras libraries, as well as the "Heart Failure Prediction" dataset from Kaggle.com. The results showed that the LSTM model with training and testing data ratio of 70:30 (Model B) achieved the best performance with accuracy of 0.869, precision of 0.869, recall of 0.869, and F1-score of 0.869. The model showed consistent ability in identifying positive and negative cases of heart failure and was effective in reducing overfitting. Overall, this research contributes to the development of more accurate and efficient heart failure disease prediction methods.

Keywords— Long Short-Term Memory, Heart Failure, Confusion Matrix, Accuracy, TensorFlow

I. PENDAHULUAN

Penyakit gagal jantung merupakan salah satu kondisi medis serius yang memengaruhi jutaan orang di seluruh dunia. Kondisi ini terjadi ketika jantung tidak mampu memompa darah secara efektif untuk memenuhi kebutuhan tubuh, yang dapat mengakibatkan berbagai komplikasi kesehatan yang parah [1]. Deteksi dini dan diagnosis yang akurat sangat penting untuk manajemen dan pengobatan yang efektif. Namun, identifikasi dan prediksi penyakit gagal jantung sering kali menjadi tantangan karena kompleksitas dan variabilitas data medis yang terkait [2].

Dalam bidang kedokteran, proses diagnosis biasanya dilakukan oleh tenaga medis berdasarkan analisis gejala, riwayat kesehatan, dan hasil tes laboratorium. Namun, metode ini memiliki beberapa keterbatasan, seperti ketergantungan pada keahlian individu, waktu yang dibutuhkan, dan potensi kesalahan manusia. Oleh karena itu, muncul kebutuhan untuk mengembangkan metode yang lebih cepat, efisien, dan akurat dalam menganalisis dan memprediksi penyakit gagal jantung. Salah satu solusi yang potensial adalah penerapan teknologi kecerdasan buatan, khususnya algoritma *Long Short-Term Memory* (LSTM).

Dalam beberapa dekade terakhir, teknologi kecerdasan buatan telah berkembang pesat dan mampu diaplikasikan dalam berbagai bidang, termasuk kedokteran dan kesehatan. Algoritma LSTM, yang merupakan jenis jaringan saraf berulang dan turunan dari Recurrent Neural Network (RNN) [3]. Metode ini telah terbukti efektif dalam menangani data sekuensial dan temporal, seperti data medis yang melibatkan riwayat kesehatan pasien [4]. LSTM mampu mempelajari pola kompleks dalam data dan memberikan prediksi yang akurat, sehingga sangat cocok untuk analisis penyakit gagal jantung.

Terdapat banyak cara untuk menganalisis dan memprediksi penyakit gagal jantung, salah satunya adalah dengan menggunakan algoritma LSTM. Algoritma ini memungkinkan komputer untuk mengenali pola dalam data medis, seperti riwayat kesehatan, hasil tes laboratorium, dan faktor risiko lainnya, yang kemudian dianalisis untuk tujuan prediksi dan diagnosis [5]. Dalam penelitian ini, kami mengimplementasikan algoritma LSTM untuk menganalisis dataset penyakit gagal jantung dan mengevaluasi tingkat akurasi yang dapat dicapai.

Penelitian ini menggunakan platform Python dengan library TensorFlow dan Keras untuk membangun dan melatih model LSTM. Dataset yang digunakan mencakup berbagai fitur seperti usia, tekanan darah, kadar kolesterol, dan faktor risiko

lainnya. Tujuan utama dari penelitian ini adalah untuk mengembangkan model prediksi yang akurat dan efisien dalam mengidentifikasi penyakit gagal jantung, sehingga dapat membantu tenaga medis dalam proses diagnosis dan manajemen pasien [6].

II. STUDI PUSTAKA

Penelitian ini didasarkan pada penelitian terdahulu yang serupa untuk mencari perbandingan, menunjukkan orisinalitas serta membantu menemukan inspirasi baru untuk penelitian selanjutnya. Pada bagian ini peneliti mencantumkan beberapa penelitian terdahulu yang serupa.

Penelitian oleh Nurillah et al. (2021) yang memprediksi pola penyebaran penyakit DBD di Kota Pagar Alam menggunakan metode Long Short Term Memory. Penelitian ini menggunakan data historial penyakit DBD Rumah Sakit Umum Daerah Basemah dan data cuaca BMKG. Penelitian ini melakukan percobaan dengan dataset tanpa preprocessing dan preprocessing terlebih dahulu dengan tiga model yang berbeda, yaitu model dengan 128 neuron, 64 neuron dan 32 neuron, yang menghasilkan konfigurasi terbaik pada dataset tanpa preprocessing dengan 32 neuron memiliki error 118.783 dan korelasi dari masing-masing daerahnya yaitu, Daerah A sebesar 0.594, Daerah B sebesar 0.420 serta Daerah C adalah sebesar 0.639 [7].

Penelitian oleh Freecenta et al. (2022) mengenai prediksi curah hujan di Kab. Malang menggunakan LSTM (Long Short Term Memory). data yang digunakan yaitu data curah hujan dengan lokasi pada daerah Kab. Malang mulai Januari 2010 sampai dengan 25 Desember 2021, dimana data pada Januari 2010 – Desember 2020 sebagai data training dan Januari 2021 – 25 Desember 2021 sebagai data testing. Pada penelitian ini menggunakan dua skenario uji coba, pertama dengan 4 layer LSTM dimana pada masing – masing layer terdapat 100 neuron. Skenario uji coba kedua dengan 2 layer LSTM dimana pada masing – masing layer terdapat 50 neuron. Nilai akurasi model tertinggi yang didapat selama penelitian ini adalah MAE sebesar 7.90, RMSE sebesar 10.16, dan nilai MSE sebesar 103.37 [8].

Penelitian oleh Ramadhan et al. (2024) mengenai prediksi polusi udara di DKI Jakarta dengan menggunakan metode Long Short Term Memory (LSTM). Prediksi dilakukan menggunakan data historis polusi udara DKI Jakarta dari tahun 2010 – 2022 dengan jumlah 4.728 data. Hasil penelitian menunjukkan bahwa model prediksi terbaik menggunakan LSTM dengan komposisi data training:datatesting 11 tahun:1 tahun, jumlah hidden layer 1, jumlah epoch 200, jumlah hidden neuron 25, jumlah batch size 16, dan learning rate 0,1 mendapatkan nilai RMSE yang berkisar antara 9,55002134344871 hingga 9,61049604442543 dari 5 kali pengujian dengan rata-rata nilai RMSE dari seluruh pengujian adalah 9,572682542 [9].


Penelitian oleh Kwanda et al. (2024) mengenai perbandingan LSTM dan Bidirectional LSTM pada sistem prediksi harga saham berbasis website. Prediksi harga saham dilakukan pada 6 perusahaan berbeda yaitu PT Bank Mandiri (Persero) Tbk, PT Bank Central Asia Tbk, PT Bank Rakyat

Indonesia (Persero) Tbk, PT Aneka Tambang Tbk, PT Adaro Energy Indonesia Tbk, dan PT Timah Tbk. Hasil penelitian ini menunjukkan bahwa model LSTM sedikit lebih unggul dibandingkan model BiLSTM dalam memprediksi kinerja PT Bank Rakyat Indonesia (BBRI), dengan selisih sekitar 0,14% berdasarkan MAPE dan 0,0009 berdasarkan MAE [10].

Penelitian yang dilakukan oleh Kavin Perdana et al. (2020) tentang Identifikasi Berita Hoax dengan recurrent Neural Network, yang kesimpulannya menyatakan bahwa Klasifikasi dengan Recurrent Neural Network menghasilkan akurasi dengan sangat baik yaitu 99% [11].

III. METODOLOGI PENELITIAN

Metodologi penelitian adalah suatu cara pengumpulan data atau informasi yang akan dianalisis. Metodologi ini membantu penulis dalam menemukan dan memecahkan masalah untuk mendukung penelitian. Penelitian ini dilakukan dengan mengikuti alur sistematis yang terdiri dari beberapa tahapan utama, mulai dari studi literatur hingga tahapan akhir yakni melakukan analisis performa secara keseluruhan. Alur penelitian dirancang untuk memastikan bahwa setiap langkah dilakukan secara terstruktur dan dapat diaplikasikan. Alur penelitian secara keseluruhan dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

1. Studi Literatur

Studi literatur merupakan salah satu tahapan para penelitian atau tahap awal dalam berbagai jenis penelitian, di mana peneliti melakukan pencarian dan analisis terhadap berbagai sumber referensi yang relevan dengan topik penelitian [12]. Tahap ini bertujuan untuk memahami konsep dasar algoritma LSTM, serta aplikasinya dalam bidang kesehatan, khususnya untuk analisis penyakit gagal jantung. Selain itu, studi literatur juga mencakup pemahaman tentang metode preprocessing data, evaluasi model, dan teknik visualisasi yang digunakan dalam penelitian serupa.

Melalui studi literatur, peneliti dapat mengidentifikasi gap research atau celah penelitian yang belum terjawab, serta menentukan pendekatan terbaik untuk mengatasi masalah

yang ada. Hasil dari tahap ini menjadi dasar untuk merancang metodologi penelitian yang sistematis dan efektif. Studi literatur juga membantu dalam memilih dataset yang sesuai, menentukan fitur-fitur penting, dan memilih metrik evaluasi yang relevan untuk mengukur performa model.

2. Pengumpulan Data

Pengumpulan data adalah tahap di mana peneliti mengumpulkan dataset yang akan digunakan dalam penelitian. Dataset yang digunakan pada penelitian ini yaitu dataset “Heart Failure Prediction” yang bersumber dari Kaggle.com yang bersifat open access. Dataset ini dibuat dengan menggabungkan berbagai dataset yang sudah tersedia secara mandiri namun belum digabungkan sebelumnya. Dalam dataset ini, kumpulan data jantung digabungkan dalam 11 fitur umum dan 1 kelas output heartdisease untuk tujuan penelitian dengan total kumpulan data observasi sebanyak 918 observasi. Dataset ini terdiri dari 410 data normal dan 508 data abnormal.

11 fitur yang ada didalam dataset tersebut mencakup Age, Sex, ChestPainType, RestingBP, Cholesterol, FastingBS, RestingECG, MaxHR, ExerciseAngina, Oldpeak, ST_Slope, HeartDisease [13]. Data yang telah terkumpul kemudian disimpan dalam format yang mudah diakses yakni file CSV untuk memudahkan proses preprocessing pada tahap selanjutnya. Berikut merupakan contoh dataset gagal jantung pada Gambar 2.

1	Age	Sex	ChestPainType	RestingBP	Cholesterol	FastingBS	RestingECG	MaxHR	ExerciseAngina	Oldpeak	ST_Slope	HeartDisease
2	40	M	ATA	140	289	0	Normal	172	N	0	Up	0
3	49	F	NAP	160	180	0	Normal	156	N	1	Flat	1
4	37	M	ATA	130	283	0	ST	98	N	0	Up	0
5	48	F	ASY	138	214	0	Normal	108	Y	1.5	Flat	1
6	54	M	NAP	150	195	0	Normal	122	N	0	Up	0
7	39	M	NAP	120	339	0	Normal	170	N	0	Up	0
8	45	F	ATA	130	237	0	Normal	170	N	0	Up	0
9	54	M	ATA	110	208	0	Normal	142	N	0	Up	0
10	37	M	ASY	140	207	0	Normal	130	Y	1.5	Flat	1
11	48	F	ATA	120	284	0	Normal	120	N	0	Up	0
12	37	F	NAP	130	211	0	Normal	142	N	0	Up	0
13	58	M	ATA	136	164	0	ST	99	Y	2	Flat	1
14	39	M	ATA	120	204	0	Normal	145	N	0	Up	0
15	49	M	ASY	140	234	0	Normal	140	Y	1	Flat	1
16	42	F	NAP	115	211	0	ST	137	N	0	Up	0

Gambar 2. Contoh Dataset

3. Desain Sistem

Desain sistem merupakan tahap perencanaan yang mencakup pembuatan arsitektur model dan alur kerja penelitian. Pada tahap ini, peneliti merancang bagaimana model LSTM akan diimplementasikan, termasuk menentukan jumlah lapisan, neuron, dan parameter lainnya. Selain itu, desain sistem juga mencakup perencanaan proses preprocessing data yang didalamnya terdapat proses encoding dan normalisasi data, lalu dilanjut implementasi método LSTM, training dan testing, prediksi dan analisis untuk mengevaluasi kinerja hasil keseluruhan, serta hasil akhir. Berikut merupakan alur desain sistem yang sudah dirancang pada Gambar 3.




Gambar 3. Desain Sistem

4. Implementasi Metode LSTM

Implementasi metode LSTM dimulai dengan membangun model menggunakan library TensorFlow dan Keras. Pada tahap ini, peneliti menentukan arsitektur model, seperti jumlah lapisan LSTM, ukuran neuron, dan fungsi aktivasi yang digunakan. Penulis menggunakan beberapa variasi hyperparameter untuk mengetahui gabungan parameter yang memiliki akurasi paling tinggi dan kinerja yang optimal. Berikut merupakan beberapa variasi hyperparameter LSTM yang digunakan:

- Variasi jumlah neuron 16 dan 32
- Variasi learning rate 0,0001 dan 0,001
- Variasi epoch dengan nilai 30 dan 50
- Variasi batch size 32 dan 64

Selain menggunakan variasi hyperparameter LSTM, penulis juga menggunakan tiga skenario uji coba dengan membagi rasio data latih dan data uji berbeda-beda. Pembagian pertama adalah model A menggunakan rasio 80% data pelatihan dan 20% data pengujian. Pembagian kedua adalah model B yang menggunakan rasio 70% data pelatihan dan 30% data pengujian. Ketiga adalah model C menggunakan rasio 60% data pelatihan dan 40% data pengujian [14]. Untuk mengetahui lebih lanjut, berikut merupakan arsitektur model LSTM pada Gambar 4.



Gambar 4. Arsitektur Model LSTM

Model kemudian diinisialisasi dan dibuat dengan Adam optimizer dan loss function yang sesuai untuk masalah klasifikasi biner. Setelah model dibangun, tahap selanjutnya adalah pelatihan model menggunakan dataset yang telah diproses. Proses pelatihan melibatkan iterasi melalui beberapa epoch untuk meminimalkan loss function dan meningkatkan akurasi model. Selama pelatihan, peneliti juga memantau performa model pada data validasi untuk menghindari overfitting. Implementasi metode ini dilakukan dengan bantuan platform Google Colab untuk memanfaatkan komputasi berbasis cloud.

5. Klasifikasi

Tahap klasifikasi adalah proses di mana model yang telah dilatih digunakan untuk memprediksi kelas dari data uji [15]. Pada penelitian ini apakah seorang pasien memiliki penyakit gagal jantung atau tidak. Pada tahap ini, data uji yang telah diproses dimasukkan ke dalam model, dan model akan menghasilkan prediksi berupa probabilitas. Probabilitas ini kemudian diubah menjadi kelas biner (0 atau 1) menggunakan threshold tertentu.

6. Performa

Tahap evaluasi performa melibatkan analisis mendalam terhadap hasil yang diperoleh dari model. Peneliti menggunakan berbagai metrik seperti akurasi, presisi, recall, dan F1-score untuk mengukur seberapa baik model bekerja. Selain itu, confusion matrix juga digunakan untuk memvisualisasikan hasil prediksi dan menganalisis kesalahan klasifikasi yang terjadi [16].

Selain metrik numerik, peneliti juga melakukan visualisasi hasil pelatihan, seperti grafik akurasi dan loss selama proses pelatihan. Visualisasi ini membantu dalam memahami perilaku model, seperti apakah model mengalami overfitting atau underfitting. Hasil evaluasi performa ini digunakan untuk menyimpulkan keefektifan model dan memberikan rekomendasi untuk perbaikan.

IV. HASIL DAN PEMBAHASAN

Adapun mengenai pembahasan yang akan dijelaskan berdasarkan permasalahan yang terjadi pada penerapan algoritma LSTM dalam analisis prediksi penyakit gagal jantung terdiri atas beberapa bagian yaitu:


A. Hasil Uji Coba Model A

Model A memiliki perbandingan yang digunakan antara data pelatihan dengan data pengujian yakni sebesar 80:20. Total hasil pengujian pada model A berjumlah 16. Dari keseluruhan hasil pengujian, berikut hasil pengujian yang memiliki variasi hyperparameter terbaik dari variasi model A

TABEL I HASIL VARIASI HYPERPARAMETER MODEL A			
Neuron	Learning Rate	Epoch	Batch Size
32	0,001	30	64

TABEL II HASIL CONFUSION MATRIX MODEL A			
Akurasi	Presisi	Recall	F1-Score
0,847	0,850	0,847	0,847


Adapun hasil visualisasi dari tabel confusion matrix pada variasi terbaik model A terdapat pada Gambar 5.



Gambar 5. Visualisasi confusion matrix model A

Berdasarkan visualisasi confusion matrix pada Gambar 5, dapat dilihat bahwa model A menunjukkan performa yang baik dalam melakukan klasifikasi. Hal ini ditunjukkan dengan nilai-nilai metrik evaluasi yang mencapai angka di atas 0.84, dimana accuracy mencapai 0.847, precision 0.850, recall 0.847, dan F1-Score 0.847. Confusion matrix yang divisualisasikan dalam bentuk heatmap menunjukkan distribusi prediksi yang seimbang antara true positive dan true negative, mengindikasikan bahwa model memiliki kemampuan yang konsisten dalam mengidentifikasi baik kasus positif maupun negatif gagal jantung.

Selain itu, terdapat juga hasil visualisasi kurva grafik akurasi dan loss selama proses pelatihan untuk model A yang terdapat pada Gambar 6.



Gambar 6. Learning curves model A

Pada Gambar 6 menampilkan learning curves yang menggambarkan proses pembelajaran model A selama training. Grafik menunjukkan tren yang positif dimana training accuracy (garis biru) meningkat secara bertahap dari epoch awal hingga mencapai stabilitas di sekitar 94% pada epoch akhir. Validation accuracy (garis oranye) juga menunjukkan peningkatan meski tidak setinggi training accuracy dan stabil di sekitar 80%. Pola ini mengindikasikan adanya overfitting yang moderat, namun masih dalam batas yang dapat diterima mengingat kompleksitas dari kasus prediksi penyakit gagal jantung. Kurva loss menunjukkan penurunan yang konsisten untuk training loss, sementara validation loss relatif stabil setelah penurunan awal, yang sejalan dengan observasi pada kurva accuracy.

B. Hasil Uji Coba Model B


Model B memiliki perbandingan yang digunakan antara data pelatihan dengan data pengujian yakni sebesar 70:30.

Total hasil pengujian pada model B berjumlah 16. Dari keseluruhan hasil pengujian, berikut hasil pengujian yang memiliki variasi hyperparameter terbaik dari variasi model B

TABEL III HASIL VARIASI HYPERPARAMETER MODEL B			
Neuron	Learning Rate	Epoch	Batch Size
16	0,001	50	64

TABEL IV HASIL CONFUSION MATRIX MODEL B			
Akurasi	Presisi	Recall	F1-Score
0,869	0,869	0,869	0,869


Adapun hasil visualisasi dari tabel confusion matrix pada variasi terbaik model B terdapat pada Gambar 7.



Gambar 7. Visualisasi confusion matrix model B

Berdasarkan visualisasi confusion matrix pada Gambar 7, model B menunjukkan performa yang sangat baik dengan nilai metrik evaluasi yang konsisten di angka 0.869 untuk semua parameter (accuracy, precision, recall, dan F1-Score). Ini merupakan peningkatan yang signifikan dibandingkan dengan model A yang sebelumnya hanya mencapai nilai sekitar 0.847. Confusion matrix yang ditampilkan dalam bentuk heatmap menunjukkan distribusi prediksi yang lebih optimal, dengan jumlah true positive dan true negative yang seimbang, mengindikasikan kemampuan model yang lebih baik dalam mengklasifikasikan kasus gagal jantung.

Selain itu, terdapat juga hasil visualisasi kurva grafik akurasi dan loss selama proses pelatihan untuk model B yang terdapat pada Gambar 8.



Gambar 8. Learning curves model B

Analisis learning curves pada Gambar 8 menunjukkan pola pembelajaran yang lebih baik dibandingkan model sebelumnya. Training accuracy (garis biru) menunjukkan

peningkatan yang lebih stabil dan mencapai konvergensi yang lebih baik, sementara validation accuracy (garis oranye) juga menunjukkan tren yang lebih positif dengan gap yang lebih kecil terhadap training accuracy. Kurva loss memperlihatkan penurunan yang lebih konsisten untuk kedua training dan validation loss, menunjukkan bahwa model B dengan 16 neuron dan learning rate 0.001 mampu mencapai generalisasi yang lebih baik dibandingkan model A. Hal ini mengindikasikan bahwa pengurangan jumlah neuron dari 32 menjadi 16 justru membantu mengurangi overfitting dan meningkatkan performa model secara keseluruhan.


C. Hasil Uji Coba Model C

Model C memiliki perbandingan yang digunakan antara data pelatihan dengan data pengujian yakni sebesar 60:40. Total hasil pengujian pada model C berjumlah 16. Dari keseluruhan hasil pengujian, berikut hasil pengujian yang memiliki variasi hyperparameter terbaik dari variasi model C

TABEL V HASIL VARIASI HYPERPARAMETER MODEL C			
Neuron	Learning Rate	Epoch	Batch Size
16	0,001	30	64

TABEL VI HASIL CONFUSION MATRIX MODEL C			
Akurasi	Presisi	Recall	F1-Score
0,841	0,846	0,841	0,840


Adapun hasil visualisasi dari tabel confusion matrix pada variasi terbaik model C terdapat pada Gambar 9.



Gambar 9. Visualisasi confusion matrix model C

Visualisasi confusion matrix pada Gambar 9 menunjukkan performa Model C dengan konfigurasi 16 neuron, learning rate 0.001, dan 30 epoch. Matrix menampilkan distribusi prediksi dengan 128 true negative dan 148 true positive, serta 36 false positive dan 16 false negative. Hasil evaluasi model menunjukkan performa yang cukup baik dengan nilai accuracy 0.841, precision 0.846, recall 0.841, dan F1-Score 0.840. Meskipun nilai ini sedikit lebih rendah dibandingkan Model B, namun masih menunjukkan kemampuan klasifikasi yang reliable dalam mengidentifikasi kasus gagal jantung.

Selain itu, terdapat juga hasil visualisasi kurva grafik akurasi dan loss selama proses pelatihan untuk model C yang terdapat pada Gambar 10.



Gambar 10. Learning curves model C

Learning curves pada Gambar 10 memperlihatkan karakteristik pembelajaran yang menarik dimana validation

V. KESIMPULAN

Penelitian ini berhasil mengimplementasikan algoritma Long Short-Term Memory (LSTM) untuk menganalisis dan memprediksi penyakit gagal jantung berdasarkan data medis pasien. Hasil penelitian menunjukkan bahwa model LSTM yang dikembangkan mampu mencapai tingkat akurasi yang cukup tinggi, dengan nilai akurasi tertinggi sebesar 0.869 pada model B yang menggunakan rasio data pelatihan dan pengujian 70:30. Model ini juga menunjukkan performa yang konsisten dalam hal presisi, recall, dan F1-score, mengindikasikan kemampuan yang baik dalam mengidentifikasi kasus positif dan negatif gagal jantung. Beberapa poin penting yang dapat disimpulkan dari penelitian ini adalah:

- Algoritma LSTM efektif dalam menangani data temporal dan sekuensial seperti data medis
- Pengaturan hyperparameter seperti jumlah neuron, learning rate, dan epoch berpengaruh signifikan terhadap performa model
- Model dengan jumlah neuron yang lebih sedikit (16 neuron) menunjukkan performa yang lebih baik dalam mengurangi overfitting
- Rasio data pelatihan dan pengujian 70:30 memberikan hasil yang optimal dibandingkan dengan rasio lainnya

Secara keseluruhan, penelitian ini memberikan kontribusi dalam pengembangan metode prediksi penyakit gagal jantung yang lebih akurat dan efisien.

REFERENSI

- [1] R. Chaudhry *et al.*, "Heart Failure: Causes, Symptoms, and Management Strategies," *J. Adv. Med. Med. Res.*, vol. 36, no. 8, pp. 335–345, Aug. 2024, doi: 10.9734/jamr/2024/v36i85551.
- [2] Y. Zeng, "Prediction and Feature Importance Analysis for Heart Failure using Machine Learning Techniques," *Trans. Comput. Sci. Intell. Syst. Res.*, vol. 5, pp. 790–796, Aug. 2024, doi: 10.62051/jp1b7v45.
- [3] K. P. Raghuvanshi, "A Systematic Literature Review on The Role of LSTM Networks in Capturing Temporal Dependencies in Data Mining Algorithms," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 12, no. 10, pp. 1219–1224, Oct. 2024, doi: 10.22214/ijraset.2024.64761.
- [4] N. Ounasser, M. Rhanoui, M. Mikram, and B. El Asri, "A brief on artificial intelligence in medicine," *Int. J. Adv. Appl. Sci.*, vol. 13, no. 4, p. 1055, Dec. 2024, doi: 10.11591/ijaas.v13.i4.pp1055-1064.

accuracy (garis oranye) pada beberapa titik menunjukkan performa yang lebih baik dibandingkan training accuracy (garis biru). Hal ini mengindikasikan bahwa model C memiliki generalisasi yang baik dan tidak mengalami overfitting yang signifikan. Kurva loss menunjukkan penurunan yang konsisten dan seimbang antara training dan validation loss, yang mengkonfirmasi bahwa model berhasil belajar dari data. Penggunaan rasio data 60:40 untuk training dan testing, serta pengurangan jumlah epoch menjadi 30 tampaknya berkontribusi pada keseimbangan performa model ini.

- [5] Yajuan Wang *et al.*, "Early detection of heart failure with varying prediction windows by structured and unstructured data in electronic health records," in *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Milan: IEEE, Aug. 2015, pp. 2530–2533. doi: 10.1109/EMBC.2015.7318907.
- [6] M. Navaei and Z. Doogchi, "Machine Learning Models for Predicting Heart Failure: Unveiling Patterns and Enhancing Precision in Cardiac Risk Assessment," Mar. 25, 2024. doi: 10.21203/rs.3.rs-4112895/v1.
- [7] R. A. S. Nurillah, M. Imrona, and A. Alamsyah, "Prediksi Pola Penyebaran Penyakit DBD di Kota Pagar Alam Menggunakan Long Short Term Memory (LSTM)," *E-Proceeding Eng.*, vol. 8, no. 1, pp. 867–882, 2021.
- [8] H. F. Freecenta, E. Yulia Puspaningrum, and H. Maulan, "Prediksi Curah Hujan Di Kab. Malang Menggunakan LSTM (Long Short Term Memory)," *J. Inform. Dan Sist. Inf.*, vol. 3, no. 1, pp. 51–55, Apr. 2022, doi: 10.33005/jifosi.v3i1.448.
- [9] A. Z. H. Ramadhan, B. Rahayudi, and D. E. Ratnawati, "Prediksi Polusi Udara di DKI Jakarta Dengan menggunakan Metode Long-Short Term Memory (LSTM)," *J. Pengemb. Teknol. Inf. Dan Ilmu Komput.*, vol. 8, no. 9, pp. 1–8, 2024.
- [10] K. Kwanda, D. E. Herwindiati, and M. D. Lauro, "Perbandingan LSTM dan Bidirectional LSTM pada Sistem Prediksi Harga Saham Berbasis Website Menggunakan Algoritma Hybrid (ARIMA-LSTM)," *Ranah Res. J. Multidiscip. Res. Dev.*, vol. 7, no. 1, pp. 26–35, Nov. 2024, doi: 10.38035/rtrj.v7i1.1255.
- [11] K. Perdana and D. N. Huda, "Identifikasi Berita Hoax dengan Recurrent Neural Network," *J. Bangkit Indonesia.*, vol. 10, no. 02, pp. 14–16, 2020.
- [12] I. Prasetyo, "Teknik analisis data dalam research and development," *Jur. PLS FIP Univ. Negeri Yogyakarta.*, 2012, Accessed: Apr. 26, 2025. [Online]. Available: <https://www.academia.edu/download/48117245/teknik-analisis-data-dalam-research-and-development.pdf>
- [13] U. Bojanić and M. Bjelica, "Predicting Heart Disease: a Comprehensive Approach to Data Analysis and Machine Learning Model Development," in *2024 IEEE 24th International Conference on Bioinformatics and Bioengineering (BIBE)*, Kragujevac, Serbia: IEEE, Nov. 2024, pp. 1–8. doi: 10.1109/BIBE63649.2024.10820449.
- [14] I. L. Rais and J. Jondri, "Klasifikasi Data Kuesioner dengan Metode Recurrent Neural Network," *E-Proceeding Eng.*, vol. 7, no. 1, pp. 2817–2826, 2020.
- [15] A. Jalil, A. Homaidi, and Z. Fatah, "Implementasi Algoritma Support Vector Machine Untuk Klasifikasi Status Stunting Pada Balita," *G-Tech J. Teknologi Terapan.*, vol. 8, no. 3, pp. 2070–2079, Jul. 2024, doi: 10.33379/gtech.v8i3.4811.
- [16] M. Salsabil, N. L. Azizah, and A. Eviyanti, "Implementasi Data Mining Dalam Melakukan Prediksi Penyakit Diabetes Menggunakan Metode Random Forest Dan Xgboost," *J. Ilmu Komputasi*, vol. 23, no. 1, Mar. 2024, doi: 10.32409/jikstik.23.1.3507.