

Klasifikasi Aritmia Pada Sinyal Elektrokardiogram Menggunakan Long-Short Term Memory Dan Variannya

1st Andini Windy Rande
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
andiniwindy08@gmail.com

2nd Tito Waluyo Purboyo
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
titowaluyo@telkomuniversity.ac.id

3rd Dziban Naufal
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
dziban@telkomuniversity.ac.id

Abstrak

Penyakit jantung merupakan penyebab kematian tertinggi di dunia, termasuk Aritmia. Pengecekan Aritmia dilakukan menggunakan alat Elektrokardiogram (EKG), analisis dilakukan oleh para profesional medis. Namun, sering kali membutuhkan waktu subjektif dan rentan terhadap kesalahan. Penelitian ini mengusulkan sistem klasifikasi Aritmia menggunakan Long-Short Term Memory (LSTM) dan Variannya. Klasifikasi dilakukan terhadap delapan jenis Aritmia menggunakan data-set MIT-BIH Arrhythmia. Penelitian ini menggunakan teknik sliding window berdasarkan jumlah (PQRST) dalam setiap episode. Hasilnya digunakan sebagai masukan untuk klasifikasi Aritmia menggunakan arsitektur LSTM, BI-LSTM dan NLSTM dengan kombinasi optimizer (Adam, RMSprop, SGD) dan batch size (16,32, 64). Melalui penelitian ini ditemukan bahwa hasil klasifikasi Aritmia dengan kombinasi arsitektur LSTM dengan ukuran window 10 kompleks PQRST, optimizer RMSprop dan batch size 32 memberikan performa terbaik dibandingkan kombinasi lainnya. Hasil yang diperoleh adalah akurasi accuracy 96.51%, precision 96.77%, recall 96.51% dan F1-score 96.56%.

Kata kunci: Aritmia, BILSTM, LSTSM, NLSTM, Klasifikasi, Ritme jantung, RNN, Sinyal ECG.

I. PENDAHULUAN

Penyakit jantung merupakan penyakit dengan tingkat mortalitas tertinggi di dunia. Terdapat 17.7 juta (31%) penduduk di dunia mengalami kematian akibat penyakit jantung[1],[2]. Beberapa pasien dengan penyakit jantung mengalami gangguan irama jantung atau aritmia. Aritmia adalah salah satu penyakit jantung yang disebabkan oleh gangguan pembangkitan impuls atau konduksi jantung, menyebabkan detak jantung menjadi tidak teratur. Secara umum aritmia tidak berbahaya tetapi, ada beberapa jenis aritmia yang menyebabkan kematian. Gejala aritmia berupa, abnormalitas pola irama jantung, palpitasi,

nyeri dada saat beraktivitas, mudah lelah, sesak nafas, sinkop, adanya gejala tromboemboli dan penurunan curah jantung[3].

Pengecekan dan pemantauan aritmia dilakukan menggunakan Elektrokardiogram (EKG)[4]. Sinyal EKG memberikan informasi penting mengenai aktivitas listrik jantung. Setelah itu, dilakukan analisis secara manual oleh profesional medis dan sering kali memakan waktu (142 ± 67 detik per EKG)[5], subjektif dan rentan terhadap kesalahan (kelalaian dan keterbatasan)[6].

Pemrosesan sinyal berbasis komputer merupakan teknik penting dalam mendiagnosis aritmia. Diagnosis menjadi lebih cepat, tepat dan objektif dalam mengidentifikasi pola sinyal yang kompleks dan beragam[7]. Long Short Term Memory (LSTM), Bidirectional LSTM dan Nested LSTM merupakan model yang mampu memodelkan ketergantungan jangka panjang pada data deret waktu seperti sinyal EKG, yang memerlukan pemahaman pola jangka pendek dan jangka panjang untuk klasifikasi aritmia [8]. Penelitian ini dilakukan untuk mengembangkan metode klasifikasi Aritmia menggunakan arsitektur LSTM, Bidirectional LSTM dan Nested LSTM secara tunggal. Penelitian-penelitian sebelumnya cenderung menggabungkan metode tersebut dengan arsitektur lain, sehingga kinerja masing-masing model secara individual masih belum dieksplorasi secara optimal dalam konteks klasifikasi Aritmia. Penelitian ini dilakukan menggunakan Massachusetts Institute of Technology – Beth Israel Hospital Arrhythmia Database[9].

II. METODE

A. Dataset

Penelitian ini dilakukan menggunakan Massachusetts Institute of Technology – Beth Israel Hospital Arrhythmia Database[9]. Dataset MIT-BIH arrhythmia database digunakan dikarenakan banyak penelitian menggunakan dataset ini, sehingga penelitian ini dapat dibandingkan dengan studi lain. Dataset ini juga telah dianotasi posisi detak dan jenis aritmia secara manual oleh ahli jantung. Selain itu, dataset ini tersedia

Identify applicable funding agency here. If none, delete this.

secara publik dan kompatibel dengan berbagai tools untuk pengolahan deep learning.

MIT-BIH Arrhythmia Database berisi 48 cuplikan rekaman sinyal Elektrokardiogram (EKG) dari 47 subjek. Setiap rekaman memiliki durasi sekitar 30 menit dan direkam menggunakan sampling frekuensi 360 Hz. Data ini mencakup 2 lead EKG untuk setiap rekaman, yaitu MLII, V1, V2, V4, dan V5 yang merekam aktivitas listrik jantung. Dalam penelitian ini, hanya saluran MLII yang digunakan untuk analisis sinyal EKG. Saluran ini dipilih karena merupakan saluran utama yang paling banyak dalam dataset. Adapun jenis aritmia yang menjadi fokus penelitian berjumlah delapan jenis, yaitu Atrial Fibrillation (AFIB), Atrial Flutter (AFL), Ventricular Bigeminy (B), Normal Sinus Rhythm (N), Nodal A-V Junctional (NOD), Paced Rhythm (P), Supraventricular Tachyarrhythmia (SVTA), dan Ventricular Tachyarrhythmia (VT). Tabel 1 menunjukkan distribusi kelas yang digunakan dalam penelitian ini.

TABEL I
DISTRIBUSI KELAS ARITMIA

Kode Aritmia	Durasi Total	Jumlah Pasien
N	17:35:26	39 Pasien
AFIB	02:12:36	8 Pasien
P	01:50:11	2 Pasien
B	00:41:50	12 Pasien
AFL	00:13:05	3 Pasien
NOD	00:04:39	3 Pasien
VT	00:03:34	13 Pasien
SVTA	00:03:30	6 Pasien

B. Pre-Processing

1) Balancing Data

Balancing data dilakukan berdasarkan durasi sinyal label aritmia. Target durasi 6 Pasien yang digunakan 10 menit (600 detik), untuk setiap kelas aritmia. Pemilihan durasi ini merupakan pertimbangan antara efisiensi komputasi dan kecukupan representasi pola sinyal, serta mempertimbangkan keterbatasan jumlah data pada beberapa jenis aritmia yang tergolong minoritas. Jika total durasi episode dari label kurang dari 10 menit, dilakukan duplikasi episode secara berulang hingga tercapai durasi target, dengan episode terakhir dipotong jika melebihi target. Sebaliknya, jika total durasi melebihi 10 menit 38 dilakukan pemilihan episode berdasarkan konstribusi perpasien, sehingga setiap pasien menyumbang durasi yang sama. Episode terakhir dari masing-masing pasien juga di potong jika diperlukan, untuk menjaga total durasi tidak melebihi target.


2) Filtering

Sinyal EKG yang belum diolah sering terkontaminasi oleh berbagai noise, seperti baseline wander, interferensi listrik, dan noise otot. Oleh karena itu diperlukan proses filter untuk menghilangkan noise. Pada penelitian ini filter yang digunakan, yaitu filter Butterworth bandpass

dan Zero Phase Filter. Filter Butterworth bandpass berfungsi menyaring frekuensi sinyal yang relevan, filter ini dipilih karena memiliki respon frekuensi yang halus, sehingga cocok untuk untuk sinyal EKG[10]. Frekuensi cutoff bandpass filter yang digunakan 0.5 Hz hingga 45 Hz. Bertujuan untuk menghilangkan noise baseline wander, yaitu noise dihasilkan oleh pernapasan, pergerakan tubuh, posisi elektro dan gangguan kabel saat pengambilan data (< 0.5 Hz) dan menyaring noise oleh interferensi listrik, yaitu noise saat sinyal EKG menangkap gelombang sinyal bolak-balik AC dari jaringan listrik (> 45 Hz)[11],[12]. Zero phase filter menerapkan filter secara dua arah (forward dan backward) untuk mencegah distorsi fasa. Keunggulan, yaitu zero phase delay, tidak memperkenalkan distorsi bentuk sinyal[13].

3) Sliding Window

Sliding Window merupakan teknik yang digunakan untuk memproses data dalam ukuran jendela (window) tertentu. Teknik ini banyak digunakan dalam berbagai bidang, termasuk pemrosesan sinyal seperti sinyal EKG. Teknik ini membagi sinyal EKG menjadi segmen-segmen kecil dengan panjang tetap (window size). Setiap segmen dapat memiliki tumpang tindih tertentu (stride) untuk menangkap informasi detail pada setiap bagian sinyal. Sliding window melibatkan penggunaan jendela yang bergerak secara bertahap sepanjang sinyal EKG, memungkinkan analisis yang lebih terfokus pada pola atau peristiwa spesifik di setiap segmen. Segmen-segmen tersebut kemudian akan menjadi input ke dalam model[14]. Pada penelitian ini, teknik sliding window akan diterapkan pada sinyal EKG. Sebelum melakukan teknik sliding window dilakukan deteksi R peaks menggunakan WFDB XQRS[15] dan segmentasi P, Q, S, T peaks menggunakan neurokit2[16]. Panjang jendela yang digunakan 3, 5 dan 10 segmen kompleks sinyal jantung. Jumlah sinyal kompleks akan ditentukan berdasarkan jumlah sinyal kompleks yang optimal dan memberikan performa terbaik berdasarkan analisis selama penelitian berlangsung. Teknik sliding window ditunjukkan pada gambar 1.



GAMBAR 1
Proses sliding window.

C. Arsitektur

1) Long Short Term Memory

Long Short Term Memory (LSTM) merupakan sebuah RNN yang dilatih menggunakan backpropagation through time yang dapat menyelesaikan permasalahan pada RNN tradisional, yaitu permasalahan vanishing gradient.

Berbeda dengan pembelajaran mesin lainnya, LSTM menggunakan memory block yang dihubungkan secara lapisan, bukan neuron [17],[18].

- Forget gate: langkah pertama yang dilakukan LSTM untuk menentukan informasi sekarang atau sebelumnya yang akan disimpan pada memory selanjutnya, informasi yang tidak disimpan akan dilupakan. Input dan hidden value digabung dan diaktivasi dengan fungsi sigmoid hanya akan mengembalikan 0 atau 1. Apabila probabilitas bernilai 0, maka nilai tersebut dilupakan; jika bernilai 1 maka nilai tersebut akan diingat[17].

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

- Input gate: menentukan seberapa penting informasi yang datang untuk menyelesaikan tugas yang dilaksanakan. Setiap input akan melalui fungsi aktivasi sigmoid untuk melihat apakah informasi tersebut penting. Fungsi aktivasi tanh akan menilai isi informasi; jika keluarannya negatif maka akan dihapus dari memori, dan jika positif maka akan ditambahkan ke dalam memori. Proses ini menghasilkan vektor kandidat sel $\tilde{C}_t$ [17].

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

- Status sel yang lama C_{t-1} diperbarui ke status yang baru C_t dengan cara mengalikan kondisi lama dengan f_t , kemudian menambahkan $i_t \times \tilde{C}_t$.

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (4)$$

- Output gate: mengirimkan informasi terbaru ke state selanjutnya berdasarkan ukuran dari model yang digunakan, informasi baru dapat menjadi informasi input pada waktu selanjutnya[17].

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

2) Bidirectional Long Short Term Memory

Bidirectional Long Short Term Memory (BI-LSTM) merupakan versi dua arah dari LSTM, terdiri dari dua lapisan LSTM, yaitu maju (forward) dan mundur (backward). BI-LSTM bisa maju mundur secara bersamaan, memungkinkan model menangkap ketergantungan jangka panjang[19]. Dalam BI-LSTM, setiap input x_t diproses oleh dua LSTM. Forward LSTM, memproses urutan dari awal hingga akhir ($x_t \rightarrow x_T$). Backward LSTM, memproses urutan dari akhir ke awal ($x_T \rightarrow x_t$). **Forward LSTM**[20]:

a) Forget Gate:

$$f_t^f = \sigma(W_f^f \cdot [h_{t-1}^f, x_t] + b_f^f) \quad (7)$$

b) Input Gate:

$$i_t^f = \sigma(W_i^f \cdot [h_{t-1}^f, x_t] + b_i^f) \quad (8)$$

c) Candidate Cell State:

$$\tilde{C}_t^f = \tanh(W_c^f \cdot [h_{t-1}^f, x_t] + b_c^f) \quad (9)$$

d) Cell State Update:

$$C_t^f = f_t^f \cdot C_{t-1}^f + i_t^f \cdot \tilde{C}_t^f \quad (10)$$

e) Output Gate:

$$o_t^f = \sigma(W_o^f \cdot [h_{t-1}^f, x_t] + b_o^f) \quad (11)$$

f) Hidden State:

$$h_t^f = o_t^f \cdot \tanh(C_t^f) \quad (12)$$

Backward LSTM[20]:

a) Forget Gate:

$$f_t^b = \sigma(W_f^b \cdot [h_{t-1}^b, x_t] + b_f^b) \quad (13)$$

b) Input Gate:

$$i_t^b = \sigma(W_i^b \cdot [h_{t-1}^b, x_t] + b_i^b) \quad (14)$$

c) Candidate Cell State:

$$\tilde{C}_t^b = \tanh(W_c^b \cdot [h_{t-1}^b, x_t] + b_c^b) \quad (15)$$

d) Cell State Update:

$$C_t^b = f_t^b \cdot C_{t-1}^b + i_t^b \cdot \tilde{C}_t^b \quad (16)$$

e) Output Gate:

$$o_t^b = \sigma(W_o^b \cdot [h_{t-1}^b, x_t] + b_o^b) \quad (17)$$

f) Hidden State:

$$h_t^b = o_t^b \cdot \tanh(C_t^b) \quad (18)$$

Melihat rumus (10),(11) h_t^f dan h_t^b mempresentasikan forward LSTM dan backward LSTM. h_t^f merupakan hidden state dari forward LSTM pada waktu t dan h_t^b merupakan hidden state dari backward LSTM pada waktu t. Kemudian output dari kedua arah digabungkan berikut persamaan BI-LSTM[21]:

$$h_t = [h_t^f, h_t^b] \quad (19)$$

$$y_t = \text{softmax}(W_y \cdot h_t + b_y) \quad (20)$$

3) Nested Long Short Term Memory

Nested Long Short Term Memory (NLSTM), merupakan LSTM yang didalamnya terdapat LSTM. NLSTM memiliki input layer, hidden layer dan output layer yang

sama dengan LSTM. NLSTM dibagi menjadi inner LSTM dan outer LSTM. NLSTM memiliki empat sistem, yaitu forget gate, input gate, candidate memory cell dan output gate[22].

a) *Forget Gate (Outer)*:

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (21)$$

b) *Input Gate (Outer)*:

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (22)$$

c) *Candidate Memory Cell (Outer)*:

$$\tilde{C}_t = \tanh(W_{cx}x_t + W_{ch}h_{t-1} + b_c) \quad (23)$$

d) *Input dari Cell dan Hidden State untuk Inner LSTM*:

$$\bar{h}_{t-1} = f_t \cdot C_{t-1} \quad (24)$$

$$\bar{x}_t = i_t \cdot \tilde{C}_t \quad (25)$$

e) *Forget Gate (Inner)*:

$$\bar{f}_t = \sigma(\bar{W}_{fx}\bar{x}_t + \bar{W}_{fh}\bar{h}_{t-1} + \bar{b}_f) \quad (26)$$

f) *Input Gate (Inner)*:

$$\bar{i}_t = \sigma(\bar{W}_{ix}\bar{x}_t + \bar{W}_{ih}\bar{h}_{t-1} + \bar{b}_i) \quad (27)$$

g) *Candidate Cell State (Inner)*:

$$\tilde{\bar{C}}_t = \tanh(\bar{W}_{cx}\bar{x}_t + \bar{W}_{ch}\bar{h}_{t-1} + \bar{b}_c) \quad (28)$$

h) *Output Gate (Inner)*:

$$\bar{o}_t = \sigma(\bar{W}_{ox}\bar{x}_t + \bar{W}_{oh}\bar{h}_{t-1} + \bar{b}_o) \quad (29)$$

i) *Update Cell State (Inner)*:

$$\bar{C}_t = \bar{f}_t \cdot \bar{C}_{t-1} + \bar{i}_t \cdot \tilde{\bar{C}}_t \quad (30)$$

j) *Hidden State (Inner)*:

$$\bar{h}_t = \bar{o}_t \cdot \tanh(\bar{C}_t) \quad (31)$$

k) *Update Memory Cell dari Outer LSTM*:

$$C_t = \bar{h}_t \quad (32)$$

l) *Output Gate (Outer)*:

$$o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (33)$$

m) *Hidden State Baru (Outer)*:


$$h_t = o_t \cdot \tanh(C_t) \quad (34)$$

III. PERANCANGAN SISTEM

Spesifikasi perangkat yang digunakan pada penelitian ini, yaitu Komputer dengan CPU core i7 gen 8. RTX 3060, 1 TB HDD, 512 SSD, 16 GB. Proses eksekusi algoritma menggunakan integrated development enviroment jupyter notebook melalui sistem operasi linux ubuntu yang mendukung bahasa pemrograman Python.

Setiap model dilatih menggunakan tiga variasi panjang window, yaitu 3, 5, dan 10 segmen sinyal kompleks jantung. Setelah itu, dilakukan pengujian terhadap tiga jenis optimizer, yaitu Adam, SGD dan RMSprop, guna mengevaluasi pengaruh optimisasi terhadap kinerja model. Selain itu, dilakukan juga pengujian terhadap tiga variasi ukuran batch size, yaitu 16, 32 dan 64 untuk mengetahui konfigurasi batch size yang optimal.

Tujuan dari seluruh rangkaian pengujian ini adalah untuk memperoleh kombinasi terbaik antara arsitektur model, panjang window, optimizer dan batch size yang mampu memberikan performa tertinggi dalam tugas klasifikasi aritmia. Evaluasi kinerja dilakukan dengan mengukur sejumlah metrik pada data uji, seperti accuracy, precision, recall, F1-score, confusion matrix dan ROC-AUC. Selain itu, performa selama proses pelatihan turut dianalisis melalui pengamatan terhadap accuracy pelatihan dan validasi, serta loss pelatihan dan validasi, untuk memastikan stabilitas dan generalisasi model.



GAMBAR 2
Diagram blok sistem.

A. Evaluasi Metrik

Analisis kinerja sistem dilakukan dengan melihat Accuracy, Precision, Recall, F1-Score, Confusion Matrix serta AUC dan ROC.

1) Accuracy

Accuracy digunakan untuk mengukur proporsi prediksi yang benar terhadap total jumlah sampel.

2) Precision

Precision digunakan untuk menunjukkan proporsi prediksi positif, berapa banyak yang benar-benar positif.

3) Recall

Recall digunakan untuk mengukur seberapa banyak data positif yang berhasil dideteksi oleh model.

4) F1-Score

F1-Score merupakan rata-rata antara precision dan recall, digunakan untuk menyeimbangkan keduanya.

5) Confusion Matrix

Confusion Matrix digunakan untuk menunjukkan performa model klasifikasi untuk setiap kelas dan menunjukkan hubungan antara label dan prediksi model.

- True Positive (TP): Model memprediksi benar dan label sebenarnya benar
- False Positive (FP): Model memprediksi benar dan label sebenarnya salah
- True Negative (TN): Model memprediksi salah dan label sebenarnya juga salah
- False Negative (FN): Model memprediksi salah dan label sebenarnya benar

6) AUC dan ROC

AUC (Area Under the Curve) dan ROC (Receiver Operating Characteristic) digunakan untuk mengevaluasi kinerja model klasifikasi.

- ROC Curve: Grafik yang memplot True Positive Rate (Recall pada sumbu Y melawan false Positive Rate pada sumbu X). Semakin tinggi area dibawah kurva, semakin baik model.
- AUC: Mengukur area di bawah kurva ROC. AUC nilai 1 menunjukkan model yang sempurna, sedangkan nilai 0.5 menunjukkan model tidak lebih baik dari tebakan secara acak.

$$Accuracy = \frac{\text{Jumlah prediksi benar}}{\text{Total jumlah sampel}} \quad (35)$$

$$Precision = \frac{TP}{TP+FP} \quad (36)$$

$$Recall = \frac{TP}{TP+FN} \quad (37)$$

$$F1-Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (38)$$

IV. HASIL DAN PEMBAHASAN

A. Analisis Perfroma Model dan Window

Dilakukan analisis berdasarkan hasil penelitian yang telah didapatkan dengan melakukan klasifikasi menggunakan tiga variasi input window serta pengujian optimizer dan batch size.

Tabel 2 menunjukkan hasil performa model yang telah diperoleh dari berbagai pengujian sebelumnya. Diperoleh hasil bahwa model LSTM dengan input window 10 kompleks menggunakan optimizer RMSprop dan batch size 32 merupakan konfigurasi terbaik. Hasil ini terlihat pada metrik evaluasi yang paling tinggi diantara semua kombinasi model dan window, dengan accuracy 96.51%, precision 96.77%, recall 96.51% dan F1-score 96.56%. Arsitektur LSTM dapat memberikan performa tertinggi karena LSTM dirancang untuk memproses data sekuensial seperti sinyal waktu, dengan kemampuan tersebut LSTM mampu menangkap ketergantungan pola jangka panjang.

Window 10 segmen kompleks sinyal jantung, memberikan akurasi terbaik karena ukuran ini memberikan konteks temporal yang cukup luas bagi model untuk memahami pola denyut jantung. Meskipun window 10 tidak selalu memberikan hasil terbaik seperti pada BI-LSTM, namun pada model LSTM window ini justru memberikan performa tertinggi. Hal ini menunjukkan bahwa kombinasi arsitektur LSTM dan cakupan window yang luas mampu menangkap informasi yang diperlukan untuk klasifikasi yang akurat.

TABEL 2
HASIL PERFORMA KESELURUHAN MODEL DENGAN VARIASI WINDOW

Model	Ukuran	Accuracy	Precision	Recall	F1-Score
LSTM	3	92.17	92.20	92.17	92.11
	5	91.17	91.97	91.92	91.89
	10	96.51	96.77	96.51	96.56
BI-LSTM	3	92.71	92.92	92.71	92.73
	5	93.94	94.16	93.94	93.92
	10	91.11	91.30	91.11	91.19
NLSTM	3	89.01	89.32	89.01	89.06
	5	93.06	93.42	93.06	93.12
	10	92.38	93.01	92.38	92.53

B. Analisis Per Kelas Aritmia

Tabel 3 menunjukkan F1-Score setiap kelas aritmia selain accuracy, F1-score juga mampu menunjukkan performa model dikarenakan F1-score mempresentasikan precision dan recall. P, SVTA dan VT memiliki F1-Score tertinggi. NOD performa baik di window kecil dan menurun di window 10 kompleks. N memiliki penurunan kecil performa pada window 10 kompleks. B sulit dikenali saat window terlalu panjang disebabkan jumlah data yang sedikit. AFL memiliki performa yang stabil. AFIB pada model NLSTM unggul di window lebih besar.

TABEL 3
F1-SCORE SETIAP KELAS ARITMIA

Class	LSTM			BI-LSTM			NLSTM		
	3	5	10	3	5	10	3	5	10
AFIB	0.86	0.87	0.86	0.87	0.82	0.86	0.77	0.86	0.89
AFL	0.92	0.93	0.90	0.91	0.93	0.88	0.88	0.92	0.91
B	0.88	0.86	0.67	0.92	0.94	0.69	0.88	0.84	0.75
N	0.87	0.90	0.82	0.81	0.87	0.84	0.84	0.90	0.82
NOD	0.91	0.95	0.85	0.93	0.97	0.85	0.84	0.90	0.78
P	0.98	0.99	0.98	0.97	0.98	0.97	0.96	0.97	0.99
SVTA	1.00	0.99	0.99	1.00	1.00	0.99	0.99	1.00	1.00
VT	0.96	0.98	0.93	0.93	1.00	0.93	0.96	0.99	0.95

V. KESIMPULAN

Penelitian ini bertujuan membangun dan mengevaluasi performa model LSTM, B-LSTM dan NLSTM dalam klasifikasi aritmia, berdasarkan kombinasi parameter panjang window sinyal, jenis optimizer dan ukuran batch size. Ketiga model diuji menggunakan panjang window 3, 5, dan 10 segmen kompleks sinyal jantung, serta variasi optimizer (Adam, RMSprop dan SGD) dan batch size (16, 32, dan 64).

Hasil penelitian menunjukkan bahwa model LSTM dengan window 10 kompleks, optimizer RMSprop, dan batch size 32 memberikan performa terbaik, dengan accuracy 96.51%, precision 96.77%, recall 96.51% dan F1-score 96.56%. Kinerja unggul LSTM disebabkan oleh arsitekturnya yang sederhana namun mampu menangkap ketergantungan jangka panjang secara efisien. Sementara itu, BI-LSTM dengan window 5 menjadi model terbaik kedua karena dapat menangkap pola secara dua arah, tetapi performanya menurun pada window lebih panjang akibat komputasi yang lebih tinggi. NLSTM menunjukkan performa terendah karena kompleksitas strukturnya yang tinggi, sehingga lebih sulit dilatih. Selain itu, keterbatasan perangkat keras juga menjadi faktor, karena model NLSTM kerap mengalami out of memory, yang membatasi eksplorasi arsitektur dan parameter secara optimal.

Performa klasifikasi per kelas menunjukkan bahwa kelas VT,

SVTA, P dan NOD sering mencapai akurasi tinggi, terutama karena duplikasi data (VT, SVTA NOD) dan pola sinyal yang konsisten (P). Sebaliknya, kelas B memiliki akurasi terendah akibat jumlah window yang sedikit. Meskipun, telah dilakukan balancing berdasarkan durasi sinyal, hal ini terjadi

karena detak jantung pada kelas B menghasilkan R peak yang lebih sedikit dalam durasi yang sama. Sedangkan AFIB dan AFL sering tertukar karena kemiripan pola sinyal dari atrium. Kelas N menunjukkan performa stabil di semua model.

DAFTAR PUSTAKA

- [1] A. Ali, E. Ifadah, and N. Hidayah, *Keperawatan Gawat Darurat: Teori dan Implementasi*. Jakarta: PT. Softpedia Publishing Indonesia, 2024.
- [2] World Health Organization, "Cardiovascular diseases (CVDs)," Jun. 11, 2021. [Online]. Available: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- [3] A. Sharma, N. Garg, S. Patidar, R. S. Tan, and U. R. Acharya, "Automated pre-screening of arrhythmia using hybrid combination of Fourier-Bessel expansion and LSTM," *Computers in Biology and Medicine*, vol. 120, p. 103753, Apr. 2020, doi: <https://doi.org/10.1016/j.combiomed.2020.103753>
- [4] S. of C. S. A. Engineering, "ECGTransForm: empowering adap-ve ECG arrhythmia classification framework with bidirectional transformer," *NTU Singapore*, 2024. [Online]. Available: <https://dr.ntu.edu.sg/handle/10356/171854>
- [5] A. H. Kashou *et al.*, "ECG Interpretation Proficiency of healthcare professionals," *Current Problems in Cardiology*, vol. 48, no. 10, p. 101924, Jul. 2023, doi: <https://doi.org/10.1016/j.cpcardiol.2023.101924>
- [6] I. Ismail, D. Purnamawati, W. Jumaiyah, and F. Rayasari, "Peningkatan Kemampuan Perawat dalam Interpretasi EKG Normal dan Aritmia dengan Metode Angka '3,'" *Jurnal Keperawatan Silampari*, vol. 4, no. 2, pp. 405–414, Mar. 2021, doi: <https://doi.org/10.31539/jks.v4i2.192410.31539/jks.v4i2.1924>
- [7] D. O. Dantas, "Cardiac Arrhythmia Detection in Electrocardiogram Signals with CNN-LSTM," *UFS-BR*, Sep. 2024. [Online]. Available: <https://www.academia.edu/116202197/CardiacArrhythmiaDetectioninElectrocardiogramsignalswithCNNLSTM>
- [8] "LSTM-Based Auto-Encoder Model for ECG Arrhythmias Classification," *IEEE Journals & Magazine*, Apr. 1, 2020. [Online]. Available: <https://ieeexplore.iee.org/document/8688435>
- [9] "MIT-BIH Arrhythmia Database V1.0.0," Feb. 24, 2005. [Online]. Available: <https://www.physionet.org/content/mitdb/1.0.0/>
- [10] "View of noise suppression of ECG signal using optimized digital Butterworth Bandpass filter." <http://ijcs.net/ijcs/index.php/ijcs/article/view/4312/684>
- [11] A. Nahar, "Adaptive Symlet filter based on ECG baseline wander removal," *Serbian Journal of Electrical Engineering*, vol. 17, no. 2, pp. 187–197, Jan. 2020, doi: 10.2298/sjee2002188n.
- [12] I. Sadiq, A. M. Zuberi, I. Zaman, A. Hassan, and T. Zaidi, "Adaptive removal of power-line interference from high resolution ECG," *Advances in Bioscience and Biotechnology*, vol. 03, no. 04, pp. 324–326, Jan. 2012, doi:10.4236/abb.2012.34047.
- [13] "filtfilt — SciPy v1.15.3 Manual." <https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.filtfilt.html>
- [14] Mandala, S., Rizal, A., Adiwijaya, N., Nurmaini, S., Amini, S. S., Sudarisman, G. A., Hau, Y. W., Abdullah, A. H. (2024b). An improved method to detect arrhythmia using ensemble learning-based model in multi lead electrocardiogram (ECG). *PLoS ONE*, 19(4), e0297551. <https://doi.org/10.1371/journal.pone.0297551>
- [15] "qrs.py - Waveform Database Software Package (WFDB) for Python." <https://www.physionet.org/content/wfdb/python/3.3.0/wfdb/processing/qrs.py>
- [16] "ECG — NeuroKit2 0.2.12 documentation." <https://neuropsychology.github.io/NeuroKit/functions/ecg.html>
- [17] "View of Sun Position Forecasting menggunakan metode RNN – LSTM sebagai referensi pengendalian daya solar cell." [Online]. Available: <https://journal.fortei7.org/index.php/sinarFe7/article/view/307/275>
- [18] A. Sherstinsky, "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network," *Physica D: Nonlinear Phenomena*, [n.d.].
- [19] L. D. Sharma, J. Rahul, A. Aggarwal, and V. K. Bohat, "An improved cardiac arrhythmia classification using stationary wavelet transform decomposed short duration QRS segment and Bi-LSTM network," *Multidimensional Systems and Signal Processing*, vol. 34, no. 2, pp. 503–520, Mar. 2023, doi: <https://doi.org/10.1007/s11045-023-00875-x>
- [20] S. M. Hashemi, R. M. Botez, and G. Ghazi, "Bidirectional Long Short-Term Memory Development for Aircraft Trajectory Prediction Applications to the UAS-S4 EHE CATL," *Aerospace*, vol. 11, no. 8, p. 625, Jul. 2024, doi: <https://doi.org/10.3390/aerospace11080625>
- [21] M. Yang *et al.*, "Design and implementation of an explainable bidirectional LSTM model based on transition system approach for cooperative AI-Workers," *Applied Sciences*, vol. 12, no. 13, p. 6390, 2022. doi: <https://doi.org/10.3390/app12136390>
- [22] K. Wang, K. Zhang, B. Liu, W. Chen, and M. Ham, "Early prediction of sudden cardiac death risk with Nested LSTM based on electrocardiogram sequential feature," *BMC Medical Informatics and Decision Making*, vol. 24, no. 1, Apr. 2024, doi: <https://doi.org/10.1186/s12911-024-02493-4>

