

Klasifikasi Aritmia Pada Sinyal Elektrokardiogram Menggunakan Gated Recurrent Unit

1st Wina Nur Annisa
Fakultas Teknik Elektro
Universitas Telkom

Kota Bandung, Indonesia
winanurannisa@student.telkomuniversity.ac.id

2nd Tito Waluyo Purboyo
Fakultas Teknik Elektro
Universitas Telkom

Kota Bandung, Indonesia
titowaluyo@telkomuniversity.ac.id

3rd Dziban Naufal
Fakultas Teknik Elektro
Universitas Telkom

Kota Bandung, Indonesia
dziban@telkomuniversity.ac.id

Abstrak — Deteksi aritmia jantung secara otomatis umumnya dilakukan melalui analisis sinyal elektrokardiogram (EKG) untuk meningkatkan akurasi dan efisiensi diagnosis. Penelitian ini mengevaluasi pengaruh variasi panjang *window* (3R, 5R, 10R) terhadap performa klasifikasi aritmia, membandingkan kinerja varian arsitektur *Gated Recurrent Unit* (GRU0–GRU4) dan *Bidirectional GRU* (BiGRU0–BiGRU4), serta menganalisis dampak konfigurasi *hyperparameter*. Dataset yang digunakan adalah MIT-BIH Arrhythmia, dengan segmentasi sinyal menggunakan metode *sliding window* berbasis jumlah puncak R. Model dilatih menggunakan fungsi *loss categorical crossentropy* dan *optimizer Adam*, dengan *tuning* pada jumlah unit (32, 64, 128), *dropout* (0.2, 0.5), dan *learning rate* (0.001, 0.0001). Evaluasi dilakukan menggunakan akurasi, ROC AUC, *precision*, *recall*, dan *F1-score*. Hasil menunjukkan bahwa *window* 3R dan model GRU0 dengan konfigurasi 128 unit, *dropout* 0.2, dan *learning rate* 0.001 menghasilkan performa terbaik, dengan akurasi 95.99%, *F1-score* 0.9599, dan akurasi validasi akhir 96.72%. Temuan ini membuktikan bahwa arsitektur GRU sederhana dengan konfigurasi optimal mampu memberikan klasifikasi aritmia berbasis EKG dengan performa tinggi.

Kata kunci— Aritmia, BiGRU, EKG, GRU, *Hyperparameter Tuning*, *Sliding Window*

I. PENDAHULUAN

Aritmia adalah gangguan irama atau laju denyut jantung yang menyebabkan jantung berdetak terlalu cepat, lambat, atau tidak teratur [1]. Kondisi ini termasuk penyakit kardiovaskular (CVD) yang berbahaya dan berkontribusi signifikan terhadap kematian global [2], dengan sekitar 19,8 juta kematian akibat CVD pada tahun 2022 atau 32% dari total kematian dunia [3]. Di Indonesia, jumlah kematian akibat CVD mencapai 651.481 jiwa per tahun [4]. Rendahnya rasio tenaga kesehatan (3,84 per 1000 penduduk) dibandingkan rekomendasi WHO (4,45 per 1000 penduduk) [5] serta kompleksitas interpretasi sinyal elektrokardiogram (EKG) menyebabkan kualitas diagnosis aritmia menurun. Evaluasi manual EKG rentan kesalahan, di mana hingga 33% interpretasi mengandung kesalahan signifikan, seperti

artefak, salah penempatan *lead*, atau kesalahan pengukuran interval [6]. Faktor ini memunculkan kebutuhan sistem deteksi aritmia otomatis yang akurat dan efisien [6], [7].

Pendekatan berbasis *deep learning* telah terbukti mampu mendeteksi aritmia secara otomatis dengan akurasi tinggi dan waktu inferensi singkat, banyak menggunakan arsitektur *hybrid* seperti CNN-LSTM [8] dan CNN-BiGRU dengan *Attention* [9]. Namun, model tersebut memiliki kompleksitas tinggi dan membutuhkan komputasi besar. Penelitian ini menguji arsitektur tunggal berbasis *Gated Recurrent Unit* (GRU) dan *Bidirectional GRU* (BiGRU) yang lebih ringan, menggunakan dataset publik MIT-BIH Arrhythmia [10]. GRU dipilih karena struktur sederhananya efektif memproses data sekuensial seperti sinyal EKG, memungkinkan pelatihan lebih cepat tanpa mengorbankan akurasi. Tujuannya adalah mencapai keseimbangan antara akurasi, efisiensi waktu, dan kesederhanaan implementasi dalam klasifikasi aritmia.

II. KAJIAN TEORI

A. Aritmia

Aritmia merupakan bagian dari kelompok penyakit kardiovaskular (CVD) yang memengaruhi sistem konduksi listrik jantung [1]. CVD mencakup berbagai kondisi seperti jantung koroner, gagal jantung, penyakit jantung hipertensi, penyakit katup jantung, dan aritmia [3]. Jenis aritmia yang berasal dari atrium meliputi *Atrial Bigeminy*, *Atrial Fibrillation* (AF), dan *Atrial Flutter*, sedangkan aritmia ventrikel meliputi *Ventricular Bigeminy*, *Ventricular Flutter*, dan *Ventricular Tachycardia* [7], [11], [12]. Irama jantung normal dikenal sebagai *Normal Sinus Rhythm*, sedangkan implus yang berasal dari nodus atrioventricular disebut *Junctional Rhythm*. *Paced Rhythm* dihasilkan oleh *pacemaker* buatan, dan *Supraventricular Tachyarrhythmia* mencakup berbagai aritmia yang berasal dari atrium atau nodus AV [11], [13].

B. Elektrofisiologi Jantung

Elektrofisiologi jantung dimulai dari impuls yang dihasilkan oleh nodus sinoatrial (SA) dan dihantarkan ke seluruh bagian jantung [11]. Proses ini melibatkan fase depolarisasi (fase 0), repolarisasi awal (fase 1), fase dataran tinggi (fase 2), repolarisasi (fase 3), dan potensial istirahat (fase 4) [12].

C. Sistem Diagnostik Menggunakan EKG

EKG merekam aktivitas listrik jantung melalui elektroda di permukaan kulit [14]. Penempatan lead pada EKG meliputi *limb leads* dan *precordial leads* [6], [14]. Laju jantung dapat dihitung menggunakan metode menghitung QRS dan metode aturan 300-150-100 [14]. Metode pertama menghitung QRS, dengan menghitung seluruh kompleks QRS pada rekaman EKG berdurasi 10 detik, kemudian mengalikannya dengan enam, dapat diperoleh nilai denyut per menit (*beats per minute*) [14]. Metode ini sangat bermanfaat ketika laju jantung bersifat tidak teratur akibat adanya variasi yang signifikan pada interval R-R antar denyut. Metode kedua adalah aturan 300-150-100. Dasar dari aturan 300-150-100 adalah menghafal nilai *beats per minute* (bpm) yang sesuai dengan interval R-R tertentu, serta memperkirakan nilai di antara rentang tersebut [14].

D. Holter Monitor

Holter monitor adalah perangkat diagnostik non-invasif yang merekam EKG secara kontinu selama 24-48 jam untuk mendeteksi aritmia intermiten [15], [16]. Perangkat ini meningkatkan probabilitas mendeteksi gangguan irama jantung seperti fibrilasi atrium atau takikardia ventrikel, serta menilai respons terhadap terapi antiaritmia [15].

E. Gated Recurrent Unit (GRU)

GRU adalah varian *Recurrent Neural Network* (RNN) yang menggunakan mekanisme *update gate* dan *reset gate* untuk mengatasi masalah *vanishing gradient* [17], [18]. Tiga varian GRU yang dikembangkan oleh Dey dan Salem (2017) adalah GRU1, GRU2, dan GRU3, yang menyederhanakan input pada fungsi gerbang sehingga mengurangi jumlah parameter [17]. Mekanisme GRU dirumuskan sebagai berikut [17]:

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (1)$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h(r_t \odot h_{t-1}) + b_h) \quad (2)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (3)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (4)$$

Pada persamaan tersebut, x_t merepresentasikan input pada waktu ke- t , sedangkan h_{t-1} adalah hidden state pada waktu sebelumnya dan h_t adalah *hidden state* pada waktu saat ini. Nilai $\tilde{h}_t$ merupakan kandidat *hidden state* yang dihasilkan sebelum diputuskan akan digunakan atau tidak. Variabel z_t disebut *update gate*, yang mengatur seberapa banyak informasi lama dipertahankan, sedangkan r_t adalah *reset gate* yang menentukan seberapa besar pengaruh informasi lama pada perhitungan *hidden state* baru. simbol W dan U menyatakan bobot pelatihan yang dipelajari oleh model, dan b adalah bias. Fungsi σ mengacu pada fungsi aktivasi sigmoid, sedangkan $\tanh$ adalah fungsi aktivasi non linier hiperbolik tangen. Simbol $\odot$ menunjukkan perkalian elemen-per-elemen atau *Hadamart product*, yaitu perkalian setiap elemen pada dua vektor dengan posisi yang sama.

Penelitian oleh Dey dan Salem (2017) memperkenalkan tiga varian *Gated Recurrent Unit* (GRU) yang dirancang dengan mengurangi jumlah parameter pada bagian fungsi gerbang, khususnya pada *update gate* dan *reset gate* [17]. Ketiga varian tersebut dinamakan GRU1, GRU2, dan GRU3, dan secara bertahap menyederhanakan input pada fungsi gerbang. Modifikasi ini bertujuan untuk mengevaluasi apakah struktur gerbang yang lebih sederhana tetap mampu mempertahankan performa prediktif, sekaligus meningkatkan efisiensi komputasi model.

1. GRU1

Setiap gerbang hanya menggunakan *hidden state* sebelumnya (h_{t-1}) dan bias sebagai input:

$$z_t = \sigma(U_z h_{t-1} + b_z) \quad (5)$$

$$r_t = \sigma(U_r h_{t-1} + b_r) \quad (6)$$

2. GRU2

Menghilangkan bias dan hanya menggunakan *hidden state* sebagai input:

$$z_t = \sigma(U_z h_{t-1}) \quad (7)$$

$$r_t = \sigma(U_r h_{t-1}) \quad (8)$$

3. GRU3

Hanya menggunakan bias sebagai input pada gerbang:

$$z_t = \sigma(b_z) \quad (9)$$

$$r_t = \sigma(b_r) \quad (10)$$

GRU1 mengurangi parameter sebesar $2 \times nm$, GRU2 sebesar $2 \times (nm + n)$, dan GRU3 sebesar $2 \times (nm + n^2)$, dibandingkan dengan GRU standar [17]. Hasil evaluasi Dey dan Salem menunjukkan bahwa GRU1 dan GRU2 mampu mencapai akurasi yang sebanding dengan GRU standar (GRU0) pada dataset MNIST dan IMDB, meskipun dengan jumlah parameter yang lebih sedikit. Sementara itu, GRU3 menunjukkan performa yang lebih rendah dalam beberapa eksperimen, terutama pada sekuens yang panjang, namun menunjukkan potensi konvergensi yang stabil bila dilatih dengan jumlah epoch yang cukup [17].

F. Bidirectional GRU (BiGRU)

BiGRU memproses data dalam dua arah, forward dan backward, untuk menangkap informasi dari masa lalu dan masa depan dalam urutan data [19]. Satu jaringan memproses data dalam arah maju (*forward*) dengan menghitung *hidden state* ($\vec{h}_t$), sedangkan jaringan lainnya memproses data dalam arah mundur (*backward*) dengan menghitung *hidden state* ($\overleftarrow{h}_t$) [19]. Berikut merupakan struktur jaringan BiGRU [19].

$$\vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \quad (11)$$


$$\overleftarrow{h}_t = \text{GRU}(x_t, \overleftarrow{h}_{t-1}) \quad (12)$$

$$h_t = W_{\vec{h}_t} \vec{h}_t + W_{\overleftarrow{h}_t} \overleftarrow{h}_t + b_t \quad (13)$$

GRU pada persamaan BiGRU merujuk pada proses komputasi jaringan GRU. Dalam arsitektur BiGRU $\vec{h}_t$ dan $W_{\vec{h}_t}$ masing-masing merepresentasikan *hidden state* dan bobot dari *hidden state* arah maju (*forward*) pada waktu t . Sementara itu, $\overleftarrow{h}_t$ dan $W_{\overleftarrow{h}_t}$ adalah *hidden state* dan bobot dari *hidden state* arah mundur (*backward*) pada waktu yang sama. Nilai b_t menunjukkan bias (offset) dari *hidden layer* pada waktu t [19].

III. METODE

Sistem klasifikasi aritmia yang dirancang divisualisasikan pada Gambar 1 berikut.



GAMBAR 1
Diagram blok sistem.

Sistem klasifikasi aritmia berbasis sinyal EKG dari MIT-BIH Arrhythmia Database, yang meliputi lima tahap utama yaitu *data preparation*, *exploratory data analysis* (EDA), *data pre-processing*, segmentasi menggunakan *sliding window*, serta pelatihan dan evaluasi model. Tahap *data preparation* mencakup pengambilan data, dilanjutkan EDA untuk memahami karakteristik sinyal. *Data pre-processing* meliputi seleksi lead, *filtering*, penghilangan noise, dan normalisasi, sebelum sinyal dibagi menjadi segmen berdurasi tetap melalui *sliding window*. Dataset hasil segmentasi digunakan untuk melatih dua arsitektur utama, yakni varian GRU dan BiGRU, yang mampu menangkap informasi temporal dua arah. Evaluasi model dilakukan menggunakan *confusion matrix*, akurasi, *precision*, *recall*, *F1-score*, ROC, dan AUC untuk menentukan arsitektur terbaik.

A. Dataset

Dataset yang digunakan dari dataset publik MIT-BIH Arrhythmia Database yang tersedia di platform PhysioNet [20]. Dataset ini terdiri dari 48 rekaman sinyal EKG dua kanal dengan frekuensi sampling 360 Hz, telah dianotasi oleh pakar kardiologi, dan memuat lebih dari 110.000 anotasi detak jantung. Dari 15 jenis anotasi ritme yang tersedia, penelitian ini memfokuskan pada delapan kelas aritmia, yaitu *Atrial Fibrillation*, *Atrial Flutter*, *Ventricular Bigeminy*, *Normal Sinus Rhythm*, *Nodal (A-V Junctional) Rhythm*, *Paced Rhythm*, *Supraventricular Tachyarrhythmia*, dan *Ventricular Tachycardia*.


B. Sliding Window

Puncak R pada sinyal EKG merupakan titik penting dalam segmentasi sinyal berbasis fisiologis, sehingga deteksi R-peak dilakukan sebelum *sliding window* dengan menggunakan pustaka Python WFDB dan NeuroKit2 yang telah divalidasi secara klinis [21], [22]. Setelah kandidat puncak R terdeteksi, dilakukan *refinement* posisi dengan menelusuri segmen ± 50 ms di sekitar tiap titik dan mengambil nilai absolut maksimum, serta *filtering* berbasis interval RR (0,3–2 detik) untuk menghilangkan deteksi palsu akibat noise. Titik R yang telah ditentukan digunakan sebagai dasar segmentasi *sliding window* berbasis jumlah R-peak [22], dengan tiga varian panjang jendela, yaitu 3R, 5R, dan 10R, untuk mengevaluasi pengaruh panjang jendela terhadap performa klasifikasi aritmia. Penentuan titik awal segmen dilakukan pada onset gelombang P sebelum R-peak pertama atau 100 ms sebelumnya jika onset tidak terdeteksi, sedangkan titik akhir berada pada offset gelombang T setelah R-peak terakhir atau 200 ms setelahnya jika offset tidak terdeteksi. *Overlapping window* digunakan dengan menggeser segmen satu puncak R untuk mempertahankan kesinambungan informasi dan meningkatkan variasi data pelatihan, seperti dirangkum pada Tabel 1.

TABEL 1
Desain skema sliding window.

Jenis Window	Jumlah R-Peak	Sliding per Step	Titik Awal	Titik Akhir
3R-peak	3	1 R-peak	P-onset R_1	T-offset R_3
5R-peak	5			T-offset R_5
10R-peak	10			T-offset R_{10}

Proses *sliding window* diilustrasikan pada Gambar 2 berikut.



GAMBAR 2
Ilustrasi sliding window.

C. Varian Model GRU (GRU0 - GRU4)

Lima varian arsitektur Gated Recurrent Unit (GRU) yang digunakan pada penelitian klasifikasi aritmia ini diadaptasi dari model referensi [26], [39] untuk mengevaluasi pengaruh modifikasi struktur gerbang terhadap performa klasifikasi aritmia berbasis sinyal EKG dari MIT-BIH Arrhythmia Database. Varian tersebut terdiri dari GRU0 sebagai model konvensional [40], GRU1–GRU3 yang dimodifikasi pada fungsi gerbang reset, update, dan pemrosesan *hidden state* berdasarkan rancangan Dey dan Salem [17], serta GRU4 sebagai model *baseline* eksplisit yang mereplikasi kelas `tf.keras.layers.GRU` pada TensorFlow. Penyesuaian ini bertujuan mengkaji potensi peningkatan performa varian hasil optimasi manual dibandingkan GRU bawaan *framework*, mengingat studi terdahulu pada MNIST menunjukkan GRU manual memiliki akurasi stabil dan konvergensi lebih panjang dibandingkan versi TensorFlow yang cenderung stagnan setelah beberapa *epoch* pelatihan [17].

D. Varian Model BiGRU (BiGRU0 - BiGRU4)

Dalam penelitian ini, lima varian model GRU (GRU0–GRU4) dikembangkan menjadi arsitektur dua arah, yaitu *Bidirectional GRU* (BiGRU), yang mengadopsi prinsip *Bidirectional Recurrent Neural Network* (Bi-RNN) untuk memproses konteks masa lalu dan masa depan secara simultan. Setiap varian BiGRU dibentuk dari dua jaringan GRU searah, masing-masing memproses input secara maju (*forward*) dan mundur (*backward*), dengan lapisan kedua menggunakan parameter `go_backwards=True`, lalu hasil keduanya digabungkan menggunakan *layer Concatenate* [41]. Pendekatan ini sejalan dengan temuan Sun et al. [29] dan Islam et al. [23] bahwa BiGRU mampu menangkap informasi temporal kompleks lebih baik dibandingkan arsitektur satu arah, sehingga meningkatkan akurasi klasifikasi aritmia pada data EKG.

E. Hyperparameter Tuning

Hyperparameter adalah parameter yang ditentukan sebelum pelatihan dan tidak diperbarui selama *backpropagation*. Penelitian ini melakukan *tuning* tiga *hyperparameter* utama, yaitu jumlah unit pada *layer* rekuren, nilai *dropout* dan *learning rate*, yang dipilih berdasarkan studi terdahulu [24], [25]. Proses *tuning* dilakukan dengan *grid search* pada ruang pencarian yang terdiri dari jumlah unit 32, 64, 128, nilai *dropout* 0.2 dan 0.5, serta *learning rate* 0.001 dan 0.0001. Eksperimen mencakup semua varian GRU (GRU0–GRU4) dan BiGRU (BiGRU0–BiGRU4) pada tiga skenario *sliding window* 3R, 5R, dan 10R, dengan *early*

stopping untuk mencegah *overfitting* dan mempertahankan bobot terbaik berdasarkan performa validasi.

IV. HASIL DAN PEMBAHASAN

A. Pengaruh Panjang Window terhadap Performa Model

Hasil pengaruh panjang window terhadap performa model didapatkan konfigurasi window 3R peak menghasilkan performa terbaik secara keseluruhan, baik dari segi akurasi, ROC AUC, precision, recall, maupun F1-score. Performa terbaik dicapai oleh model GRU0 dengan akurasi sebesar 95.99% dan F1-score sebesar 0.9599, serta akurasi validasi akhir sebesar 96.72%. Performa model cenderung menurun seiring dengan bertambahnya panjang window. Hal ini menunjukkan bahwa penggunaan window yang terlalu panjang (seperti 10R peak) berpotensi memasukkan informasi yang *redundant* atau *noise*, sehingga justru mengurangi kemampuan model dalam membedakan pola aritmia.

B. Perbandingan Performa Varian Arsitektur GRU dan BiGRU

Tabel 4.12 membandingkan performa GRU dan BiGRU terbaik dari seluruh konfigurasi panjang window 3R, 5R, dan 10R berdasarkan akurasi tertinggi, dengan metrik evaluasi *accuracy*, ROC AUC, precision, recall, F1-score, dan *final val acc*.

TABEL 2
Perbandingan performa model GRU dan BiGRU.

Model	Accura cy	ROC AUC	Preci on	Reca ll	F1-Scor e	Final Val Acc
GRU0	95.99%	0.9959	0.9593	0.9609	0.9599	96.72%
BiGRU4	95.23%	0.9976	0.9523	0.9526	0.9516	96.61%

Berdasarkan Tabel 4.12, GRU0 menunjukkan performa lebih tinggi dibandingkan BiGRU4 pada seluruh metrik utama, dengan akurasi 95.99% dan F1-score 0.9599, unggul dari BiGRU4 yang memiliki akurasi 95.23% dan F1-score 0.9516. Meskipun ROC AUC BiGRU4 sedikit lebih tinggi (0.9976) dibandingkan GRU0 (0.9959), selisihnya sangat kecil dan tidak diikuti peningkatan metrik lainnya. Model GRU0 sebagai implementasi GRU konvensional [16] terbukti lebih stabil dan unggul dibandingkan varian modifikasi GRU1–GRU3 maupun BiGRU1–BiGRU3, sehingga penambahan kompleksitas arsitektur melalui mekanisme bidirectional pada BiGRU tidak selalu memberikan keuntungan signifikan untuk klasifikasi sinyal EKG.


C. Pengaruh Konfigurasi Hyperparameter terhadap Performa Model

Pada konfigurasi *hyperparameter* model varian GRU menunjukkan performa tertinggi dicapai oleh GRU0 pada kombinasi *hyperparameter* unit 128, dropout 0.2, learning rate 0.001, dan window 3R dengan *accuracy* sebesar 95.99%, *F1-score* sebesar 0.9599, dan *final validation accuracy* sebesar 96.72%. Pada model BiGRU kombinasi *hyperparameter* jumlah unit sebesar 128, dropout sebesar 0.5, dan learning rate 0.001 menghasilkan performa model yang

baik yaitu *accuracy* sebesar 95.23%, *F1-score* 0.9516, dan *final validation accuracy* 96.61%. Hasil tersebut merupakan hasil dari model BiGRU4 pada window 5R *peak*.

D. Evaluasi Model Terbaik


Berdasarkan seluruh eksperimen yang telah dilakukan pada variasi panjang window, arsitektur model (GRU0–GRU4 dan BiGRU0–BiGRU4), serta konfigurasi hyperparameter, model dengan performa terbaik secara keseluruhan adalah GRU0 dengan konfigurasi window 3R *peak*, units 128, dropout 0.2, learning rate 0.001. Model ini menunjukkan performa klasifikasi tertinggi pada metrik global dengan akurasi 95.99%, *F1-score* 0.9599, dan *final validation accuracy* sebesar 96.72%. Konfigurasi ini juga menunjukkan kestabilan pelatihan yang baik, seperti ditampilkan pada Gambar 4.4 yang memperlihatkan kurva akurasi dan loss selama proses pelatihan.



GAMBAR 3

Kurva akurasi (kiri) dan loss (kanan) model GRU0 (units=128; dropout=0.2; learning rate=0.001).


Selanjutnya, Gambar 4 menampilkan confusion matrix dari model GRU0. Confusion matrix ini menunjukkan bahwa model mampu mengenali sebagian besar label aritmia dengan sangat baik, dengan proporsi prediksi benar yang dominan di diagonal.



GAMBAR 4

Confusion Matrix model GRU0 (units=128; dropout=0.2; learning rate=0.001).

Kemampuan diskriminatif model terhadap setiap label ditunjukkan dalam Gambar 4.6 berupa kurva ROC AUC, yang mengonfirmasi bahwa seluruh kelas aritmia memiliki area under curve (AUC) di atas 0.99. Hal ini mengindikasikan bahwa model tidak hanya akurat, tetapi juga mampu membedakan dengan jelas antar label.



GAMBAR 5
Kurva ROC AUC.

Untuk mengevaluasi performa model secara lebih mendalam, dilakukan analisis terhadap masing-masing label aritmia yang disajikan dalam Tabel 4.23. Hasilnya, model mampu mengklasifikasikan label P, SVTA, dan VT dengan F1-score hampir sempurna (≥ 0.99). Sementara itu, label seperti AFIB dan N masih menunjukkan performa sangat baik dengan F1-score di atas 0.90, meskipun sedikit lebih rendah dari label lainnya. Seluruh nilai AUC berada pada rentang 0.99–1.00, menunjukkan bahwa model memiliki kemampuan yang sangat kuat dalam mendeteksi pola-pola aritmia yang berbeda.

Tabel 3 Evaluasi model GRU0 per Label.

Label	Accuracy	Precision	Recall	F1-Score	AUC
AFIB	0.89	0.94	0.89	0.91	0.99
AFL	0.92	0.92	0.92	0.92	0.99
B	0.96	0.93	0.96	0.95	1
N	0.93	0.95	0.93	0.94	0.99
NOD	1	0.94	1	0.97	1
P	0.98	0.99	0.98	0.99	1
SVTA	0.99	1	0.99	1	1
VT	1	0.95	1	0.97	1

V. KESIMPULAN

Berdasarkan penelitian ini, sliding window 3R peak memberikan performa klasifikasi terbaik dibandingkan 5R dan 10R peak, dengan tren penurunan akurasi pada window yang lebih panjang. Perbandingan arsitektur menunjukkan GRU0, implementasi GRU konvensional oleh Cho et al., mengungguli varian modifikasi GRU1–GRU3 dan BiGRU1–BiGRU3, sehingga modifikasi gate atau penambahan arah pemrosesan tidak selalu meningkatkan kinerja. Tuning hyperparameter menunjukkan konfigurasi optimal terdiri dari 128 unit, *dropout* 0.2, dan *learning rate* 0.001, yang menghasilkan akurasi 95.99%, F1-score 0.9599, dan *final validation accuracy* 96.72%. Secara keseluruhan, GRU0 dengan konfigurasi ini menjadi model terbaik untuk klasifikasi aritmia berbasis sinyal EKG.

REFERENSI

[1] “Arrhythmias - What Is an Arrhythmia? | NHLBI, NIH,” National Heart, Lung, and Blood Institute.
[2] B. Azeem *et al.*, “Unmasking Arrhythmia Mortality: A 25-Year Analysis of Trends and Disparities in the

United States (1999–2023),” *Clin Cardiol*, vol. 48, no. 3, Mar. 2025, doi: 10.1002/clc.70109.
[3] World Health Organization, “Cardiovascular diseases (CVDs),” WHO.
[4] Marsha Anindita, “Peringatan Hari Jantung Sedunia 2021: Jaga Jantungmu untuk Hidup Lebih Sehat,” Ayo Sehat Kemenkes.
[5] F. R. Muharram *et al.*, “Adequacy and Distribution of the Health Workforce in Indonesia,” pp. 45–55, Jul. 2024, doi: 10.4103/WHO-SEAJPH.WHO-SEAJPH_28_24.
[6] C. J. Breen, G. P. Kelly, and W. G. Kernohan, “ECG interpretation skill acquisition: A review of learning, teaching and assessment,” Jul. 01, 2022, *Elsevier B.V.* doi: 10.1016/j.jelectrocard.2019.03.010.
[7] J. A. Joglar *et al.*, “2023 ACC/AHA/ACCP/HRS Guideline for the Diagnosis and Management of Atrial Fibrillation: A Report of the American College of Cardiology/American Heart Association Joint Committee on Clinical Practice Guidelines,” Jan. 2024, *Lippincott Williams and Wilkins*. doi: 10.1161/CIR.0000000000001193.
[8] P. Madan, V. Singh, D. P. Singh, M. Diwakar, B. Pant, and A. Kishor, “A Hybrid Deep Learning Approach for ECG-Based Arrhythmia Classification,” *Bioengineering*, vol. 9, no. 4, Apr. 2022, doi: 10.3390/bioengineering9040152.
[9] X. Bai, X. Dong, Y. Li, R. Liu, and H. Zhang, “A hybrid deep learning network for automatic diagnosis of cardiac arrhythmia based on 12-lead ECG,” *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-75531-w.
[10] Y. Ansari, O. Mourad, K. Qaraqe, and E. Serpedin, “Deep learning for ECG Arrhythmia detection and classification: an overview of progress for period 2017–2023,” 2023, *Frontiers Media SA*. doi: 10.3389/fphys.2023.1246746.
[11] D. S. Desai and S. Hajouli, “Arrhythmias,” in <https://www.ncbi.nlm.nih.gov/books/NBK558923/>, vol. 4, Elsevier, 2023, p. V4:432-V4:468.
[12] J. Grune, M. Yamazoe, and M. Nahrendorf, “Electroimmunology and cardiac arrhythmia,” Aug. 2021, *Nature Research*. doi: 10.1038/s41569-021-00520-9.
[13] “Arrhythmias,” <https://www.nhlbi.nih.gov/health/arrhythmias>.
[14] U. Kharad, M. Benayon, and L. Latchupatula, “ECG Basics,” ECG Essentials.
[15] P. R. Kowey and D. Z. Kocovic, “Ambulatory Electrocardiographic Recording,” *Circulation*, vol. 108, no. 5, Aug. 2003, doi: 10.1161/01.CIR.0000082930.04238.8C.
[16] C. W. Israel and S. Tribunyan, “Holter monitoring,” *Herzschrittmachertherapie + Elektrophysiologie*, vol. 35, pp. 234–249, Aug. 2024.
[17] R. Dey and F. M. Salemt, “Gate-variants of Gated Recurrent Unit (GRU) neural networks,” in *Midwest Symposium on Circuits and Systems*, Institute of Electrical and Electronics Engineers Inc., Sep. 2017, pp. 1597–1600. doi: 10.1109/MWSCAS.2017.8053243.

- [18] F. M. Salem, "Gated RNN: The Gated Recurrent Unit (GRU) RNN," in *Recurrent Neural Networks*, Springer International Publishing, 2022, pp. 85–100. doi: 10.1007/978-3-030-89929-5_5.
- [19] Y. Sun, J. Zhang, Z. Yu, Y. Zhang, and Z. Liu, "The Bidirectional Gated Recurrent Unit Network Based on the Inception Module (Inception-BiGRU) Predicts the Missing Data by Well Logging Data," *ACS Omega*, vol. 8, pp. 27710–27724, Jul. 2023, doi: 10.1021/acsomega.3c03677.
- [20] G. Moody and R. Mark, "MIT-BIH Arrhythmia Database," PhysioNet.
- [21] F. Ansari, "NOISE REDUCTION IN ECG BY IIR FILTERS: A COMPARATIVE STUDY." [Online]. Available: <https://www.researchgate.net/publication/344508453>
- [22] S. Mandala *et al.*, "An improved method to detect arrhythmia using ensemble learning-based model in multi lead electrocardiogram (ECG)," *PLoS One*, vol. 19, Apr. 2024, doi: 10.1371/journal.pone.0297551.
- [23] "tf.keras.layers.RNN | TensorFlow v2.16.1," TensorFlow. Accessed: Jul. 14, 2025. [Online]. Available: https://www.tensorflow.org/api_docs/python/tf/keras/layers/RNN
- [24] N. Reimers and I. Gurevych, "Optimal Hyperparameters for Deep LSTM-Networks for Sequence Labeling Tasks," Aug. 2017.
- [25] S. Merity, N. S. Keskar, and R. Socher, "An Analysis of Neural Language Modeling at Multiple Scales," Mar. 2018.