

REGIME-AWARE LSTM DENGAN ADAPTIVE DUAL-TIMESCALE TEMPORAL ENCODING UNTUK PEMODELAN DINAMIKA JANTUNG DAN DETEKSI ARITMIA

WIWIET HERULAMBANG^[1], RIKA ROKHANA^[2], RARASMAYA INDRASWARI^[3],
GAGATSATYA ADIATMAJA^[4]

^[1]Teknik Informatika, Universitas Bhayangkara Surabaya

^[2]Teknik Elektro, Politeknik Elektronika Negeri Surabaya

^{[3],[4]}Sistem Informasi, Institut Teknologi Sepuluh Nopember Surabaya

Emails: ^[1]herulambang@ubhara.ac.id, ^[2]rika@pens.ac.id, ^[3]rarasmaya@its.ac.id,

^[4]gagatsatya@its.ac.id

ABSTRACT

Electrocardiogram (ECG)-based arrhythmia detection remains a critical challenge due to nonlinear heartbeat variability, temporal instability, and dynamic cardiac regime transitions. Conventional Long Short-Term Memory (LSTM) networks are capable of learning sequential ECG patterns; however, they often struggle to simultaneously represent short-term and long-term cardiac temporal dynamics. This study proposes a Regime-Aware LSTM framework integrated with Adaptive Dual-Timescale Temporal Encoding (RADTTE) for cardiac dynamics modeling and arrhythmia detection. The proposed approach introduces exponentially weighted temporal representations operating at dual timescales to capture adaptive cardiac regime transitions from RR interval sequences. The framework extracts short-term and long-term temporal cardiac dynamics prior to sequential modeling using an LSTM architecture. Experiments were conducted using the MIT-BIH Arrhythmia Database consisting of annotated ECG recordings. The proposed framework was compared against a conventional LSTM baseline using accuracy, precision, recall, F1-score, specificity, and ROC-AUC metrics. Experimental results demonstrate that the proposed method achieved superior performance with improved anomaly sensitivity and reduced false positive rates. The proposed model achieved 98.1% accuracy and a 97.0% F1-score, outperforming the conventional LSTM baseline. The findings indicate that regime-aware temporal representation significantly enhances sequential cardiac anomaly modeling and improves arrhythmia transition detection.

Keywords: Arrhythmia Detection, ECG, RADTTE-LSTM, Regime-Aware Modeling, Temporal Encoding

ABSTRAK

Deteksi aritmia berbasis Elektrokardiogram (EKG) masih menjadi tantangan penting karena adanya variabilitas detak jantung yang non-linear, ketidakstabilan temporal, dan transisi rezim jantung yang dinamis. Jaringan Long Short-Term Memory (LSTM) konvensional mampu mempelajari pola EKG sekuensial; namun, metode ini sering kali kesulitan untuk secara bersamaan merepresentasikan dinamika temporal jantung jangka pendek dan jangka panjang. Penelitian ini mengusulkan kerangka kerja Regime-Aware LSTM yang diintegrasikan dengan Pengkodean Temporal Skala Waktu Ganda Adaptif (Adaptive Dual-Timescale Temporal Encoding/RADTTE) untuk pemodelan dinamika jantung dan deteksi aritmia. Pendekatan yang diusulkan ini memperkenalkan representasi temporal berbobot eksponensial yang beroperasi pada skala waktu ganda untuk menangkap transisi rezim jantung adaptif dari urutan interval RR. Kerangka kerja ini mengekstraksi dinamika jantung temporal jangka pendek dan jangka panjang sebelum dilakukan pemodelan sekuensial menggunakan arsitektur LSTM. Eksperimen dilakukan menggunakan Basis Data Aritmia MIT-BIH yang terdiri dari rekaman EKG beranotasi. Kerangka kerja yang diusulkan dibandingkan dengan model dasar LSTM konvensional

menggunakan metrik akurasi, presisi, recall, skor-F1, spesifisitas, dan ROC-AUC. Hasil eksperimen menunjukkan bahwa metode yang diusulkan mencapai kinerja superior dengan peningkatan sensitivitas anomali dan penurunan rasio positif palsu (*false positive rate*). Model yang diusulkan mencapai akurasi sebesar 98,1% dan skor-F1 sebesar 97,0%, mengungguli model dasar LSTM konvensional. Temuan ini mengindikasikan bahwa representasi temporal *regime-aware* secara signifikan meningkatkan pemodelan anomali jantung sekuensial dan memperbaiki deteksi transisi aritmia.

Kata kunci: Deteksi Aritmia, EKG, RADTTE-LSTM, Pemodelan *Regime-aware*, temporal encoding

1. PENDAHULUAN

Penyakit kardiovaskular tetap menjadi salah satu penyebab utama kematian di seluruh dunia dan terus menjadi beban perawatan kesehatan global yang besar (Goldberger et al., 2023). Di antara berbagai gangguan jantung, aritmia ditandai dengan aktivitas kelistrikan yang abnormal dan pola irama jantung yang tidak teratur yang dapat memicu komplikasi parah, termasuk gagal jantung dan kematian jantung mendadak. Oleh karena itu, deteksi aritmia dini secara klinis sangat penting untuk meningkatkan akurasi diagnostik dan mengurangi risiko kematian. Kemajuan terbaru dalam perangkat kesehatan yang dapat dikenakan (*wearable devices*) dan kecerdasan buatan telah mempercepat laju penelitian dalam analisis Elektrokardiogram (EKG) otomatis secara signifikan (Dai et al., 2024).

Pendekatan pembelajaran mendalam (*deep learning*) seperti Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN), dan jaringan Long Short-Term Memory (LSTM) telah diterapkan secara luas untuk klasifikasi EKG dan deteksi aritmia (Alfaras et al., 2023; Wang et al., 2023). Di antara metode-metode tersebut, LSTM telah menunjukkan kemampuan yang kuat dalam memodelkan ketergantungan temporal pada sinyal EKG sekuensial. Penelitian terbaru lebih lanjut menunjukkan bahwa pembelajaran temporal multiskala dan representasi sekuensial adaptif secara signifikan meningkatkan kinerja deteksi anomali jantung (Boukhalfa et al., 2024; Rahman et al., 2024). Namun demikian, sebagian besar penelitian sebelumnya terutama berfokus pada klasifikasi berbasis detak (*beat-wise*) sembari mengabaikan transisi rezim jantung adaptif dan dinamika ketidakstabilan temporal multiskala.

Dalam kondisi fisiologis yang realistis, kelainan jantung jarang muncul secara instan. Sebaliknya, permulaan aritmia sering kali didahului oleh ketidakstabilan detak jantung yang bertahap, perluasan variabilitas detak jantung, dan ketidakaturan interval RR yang progresif. Model LSTM konvensional sering kali gagal menangkap dinamika transisi adaptif ini secara efektif. Kerangka kerja EKG berbasis transformer baru-baru ini menunjukkan bahwa pembelajaran representasi temporal jarak jauh penting untuk memodelkan dinamika jantung yang kompleks; namun, model semacam ini sering kali memerlukan sumber daya komputasi yang besar (Chen et al., 2023).

Beberapa penelitian terdahulu menekankan ekstraksi fitur lokal berbasis CNN dan pembelajaran sekuensial berulang untuk analisis EKG (Gao et al., 2023; Yoon et al., 2024). Selain itu, mekanisme atensi temporal yang dapat dijelaskan (*explainable temporal attention*) baru-baru ini telah diperkenalkan untuk mengidentifikasi dinamika jantung yang tidak stabil sebelum permulaan aritmia (Dai et al., 2024). Akan tetapi, masih terbatasnya penelitian yang secara eksplisit menyelidiki pemodelan dinamika jantung sadar-rezim menggunakan representasi temporal multiskala adaptif. Studi terbaru oleh Kim et al. (2024) dan Xu et al. (2025) menyoroti pentingnya pemodelan transisi rezim jantung untuk deteksi anomali sekuensial, yang mengindikasikan bahwa anomali EKG harus diinterpretasikan sebagai transisi keadaan fisiologis dinamis, alih-alih sebagai kejadian klasifikasi detak jantung yang terisolasi.

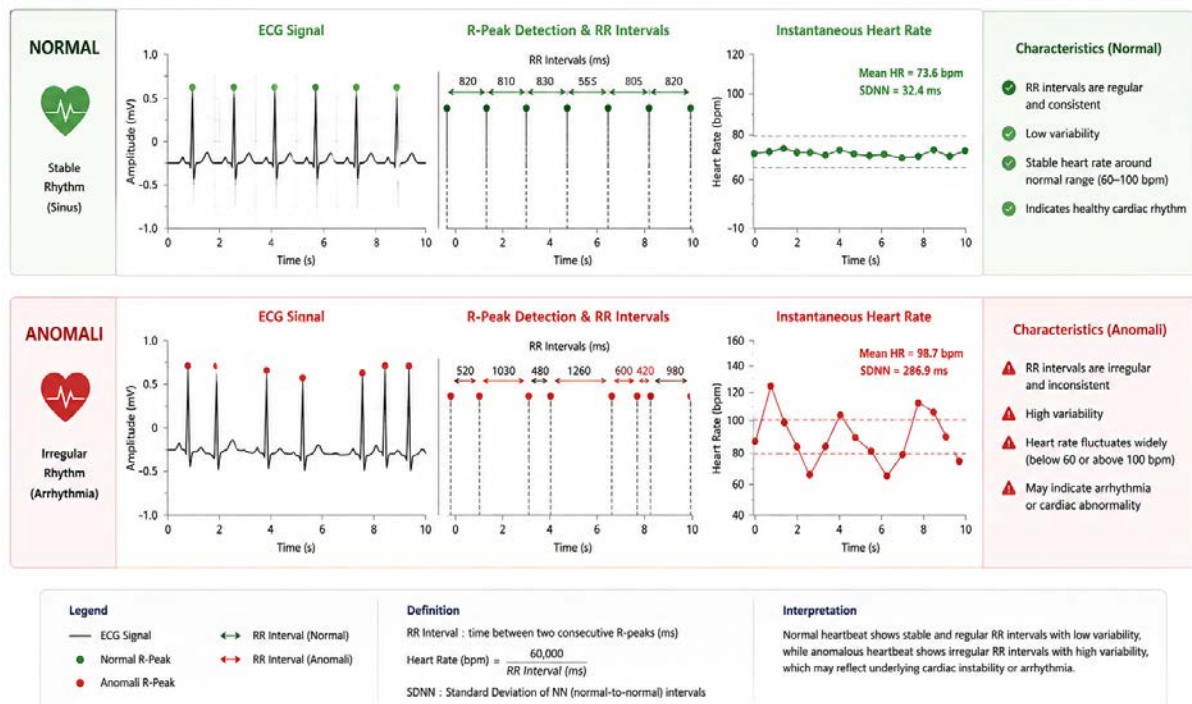
Oleh karena itu, penelitian ini mengusulkan kerangka kerja LSTM *Regime-aware* yang diintegrasikan dengan Pengkodean Temporal Skala Waktu Ganda Adaptif (RADTTE) untuk memodelkan dinamika temporal jantung dan meningkatkan deteksi aritmia. Berbeda dengan pendekatan LSTM konvensional yang secara langsung memproses urutan interval RR mentah,

kerangka kerja yang diusulkan ini memperkenalkan representasi temporal sadar-transisi-rezim yang mampu secara bersamaan memodelkan dinamika jantung temporal jangka pendek dan jangka panjang.

Kontribusi utama dari penelitian ini dirangkum sebagai berikut:

1. Pengembangan Pengkodean Temporal Skala Waktu Ganda Adaptif untuk ekstraksi fitur temporal jantung.
2. Pengenalan representasi dinamika jantung *regime-aware* menggunakan pemodelan temporal multiskala.
3. Peningkatan kinerja dibandingkan dengan deteksi aritmia berbasis LSTM konvensional.
4. Analisis transisi rezim jantung menggunakan dinamika temporal interval RR.

HEARTBEAT RATE (RR INTERVAL) COMPARISON: NORMAL vs ANOMALI



Gambar 1. Laju Detak Jantung dari EKG - Normal vs Anomali

2. TEORI

2.1 ELEKTROKARDIOGRAM (EKG)

Elektrokardiografi (EKG) adalah teknik diagnostik non-invasif yang digunakan untuk merekam aktivitas kelistrikan jantung dan secara luas dimanfaatkan untuk diagnosis penyakit kardiovaskular serta pemantauan aritmia (Goldberger et al., 2023). Sinyal EKG terdiri dari beberapa komponen bentuk gelombang karakteristik, termasuk gelombang P, kompleks QRS, dan gelombang T, yang masing-masing mewakili aktivitas fisiologis kelistrikan jantung tertentu. Di antara fitur temporal terpenting yang diekstraksi dari sinyal EKG adalah interval RR, yang mewakili jarak temporal antara puncak R yang berurutan dan mencerminkan variabilitas irama detak jantung.

Studi terbaru membuktikan bahwa dinamika interval RR memberikan informasi krusial untuk analisis anomali jantung, khususnya untuk mendeteksi ketidakstabilan detak jantung dan transisi aritmia (Li et al., 2025; Dai et al., 2024). Lebih lanjut, pembelajaran representasi EKG multiskala telah

menunjukkan bahwa variabilitas detak jantung temporal mengandung informasi sekuensial yang berharga melampaui klasifikasi morfologi detak konvensional (Chen et al., 2023).

2.2 LONG SHORT-TERM MEMORY (LSTM)

Long Short-Term Memory (LSTM) adalah arsitektur recurrent neural network khusus yang dirancang untuk mengatasi masalah vanishing gradient yang umumnya ditemui dalam tugas-tugas pembelajaran sekuensial. Arsitektur LSTM menggunakan sel memori yang diatur oleh gerbang masukan (input gates), gerbang lupa (forget gates), dan gerbang keluaran (output gates), yang memungkinkan pembelajaran ketergantungan temporal jangka panjang secara efektif (Wang et al., 2023).

Jaringan LSTM telah diterapkan secara ekstensif pada klasifikasi EKG dan deteksi aritmia karena kemampuannya dalam memodelkan dinamika detak jantung sekuensial (Alfaras et al., 2023). Penelitian terbaru selanjutnya mendemonstrasikan bahwa arsitektur sekuensial berulang tetap sangat efektif untuk analisis EKG yang ringan (lightweight) dan seketika (real-time), terutama pada sistem perawatan kesehatan *wearable* di mana efisiensi komputasi sangat esensial (Yoon et al., 2024).

Terlepas dari keuntungan ini, model LSTM konvensional sering kali berjuang keras untuk menangkap transisi rezim jantung adaptif dan ketidakstabilan detak jantung yang progresif karena model tersebut secara langsung memproses urutan temporal mentah tanpa representasi temporal multiskala eksplisit (Rahman et al., 2024). Akibatnya, beberapa penelitian baru-baru ini mengusulkan kerangka kerja pembelajaran sekuensial adaptif untuk meningkatkan sensitivitas temporal dalam deteksi anomali EKG (Gao et al., 2023).

2.3 TEMPORAL ENCODING

Pengkodean temporal adalah teknik pembelajaran representasi yang digunakan untuk memodelkan pola evolusi temporal dalam data sekuensial. Dalam analisis EKG, pengkodean temporal memungkinkan jaringan saraf untuk menangkap variabilitas detak jantung, evolusi ritme, dan pola ketidakstabilan temporal di berbagai skala waktu (Boukhalfa et al., 2024).

Penelitian terbaru menunjukkan bahwa pengkodean temporal multiskala adaptif secara signifikan meningkatkan sensitivitas anomali jantung dengan secara bersamaan merepresentasikan dinamika detak jantung jangka pendek dan jangka panjang (Rahman et al., 2024; Yoon et al., 2024). Kerangka kerja EKG berbasis transformer juga menyoroti pentingnya pembelajaran representasi temporal untuk menangkap ketergantungan jantung jarak jauh dan transisi fisiologis (Chen et al., 2023).

Dalam studi ini, Pengkodean Temporal Skala Waktu Ganda Adaptif (ADTTE) diperkenalkan untuk memodelkan dinamika temporal jantung menggunakan representasi temporal berbobot eksponensial. Mekanisme pengkodean yang diusulkan terdiri dari pengkodean temporal cepat dan pengkodean temporal lambat untuk merepresentasikan fluktuasi detak jantung jangka pendek dan evolusi irama jangka panjang secara simultan.

2.4 PEMODELAN REGIME-AWARE

Pemodelan sadar-rezim (*regime-aware*) memandang data deret waktu (time-series) sebagai sistem transisi-keadaan dinamis yang terdiri dari beberapa rezim temporal alih-alih sebagai observasi yang terisolasi (Kim et al., 2024). Dalam analisis EKG, rezim jantung dapat mewakili kondisi fisiologis yang stabil, transisional, tidak stabil, atau aritmia.

Penelitian terbaru menekankan bahwa kemunculan aritmia sering kali didahului oleh transisi ketidakstabilan jantung secara bertahap yang ditandai dengan ketidakaturan interval RR dan peningkatan variabilitas detak jantung (Xu et al., 2025). Oleh karena itu, deteksi anomali sekuensial harus diinterpretasikan sebagai pemodelan transisi rezim fisiologis dinamis, dan bukan semata-mata sebagai klasifikasi detak jantung statis.

Beberapa kerangka kerja EKG modern telah memasukkan pembelajaran temporal adaptif dan representasi sekuensial yang sadar akan ketidakstabilan untuk meningkatkan kinerja deteksi anomali (Dai et al., 2024; Li et al., 2025). Meskipun demikian, riset yang secara eksplisit mengintegrasikan representasi temporal sadar-rezim ke dalam arsitektur saraf berulang yang ringan untuk deteksi anomali EKG masih terbatas.

Kerangka kerja yang diusulkan mengatasi keterbatasan ini dengan mengintegrasikan Pengkodean Temporal Skala Waktu Ganda Adaptif ke dalam arsitektur LSTM Sadar-Rezim, yang memungkinkan model tersebut menangkap transisi ketidakstabilan jantung progresif dan evolusi rezim detak jantung adaptif secara lebih efektif.

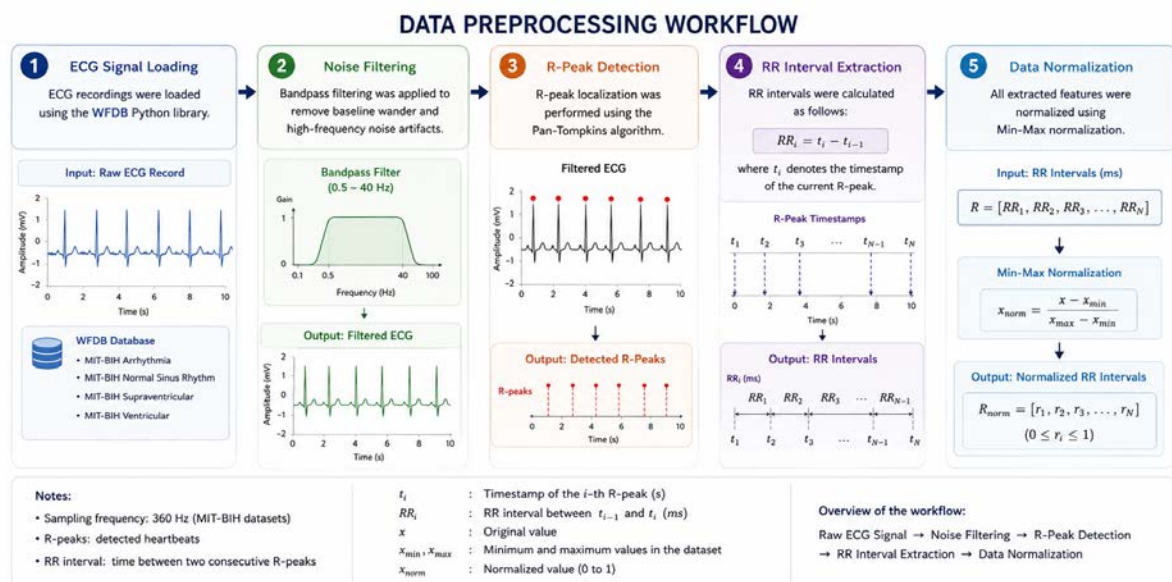
3. METODE

3.1 DATASET

Penelitian ini memanfaatkan Basis Data Aritmia MIT-BIH yang disediakan oleh PhysioNet. Dataset ini terdiri dari 48 rekaman EKG beranotasi yang disampling pada frekuensi 360 Hz dengan berbagai kategori aritmia.

3.2 DATA PREPROCESSING

Tahap pra-pemrosesan dilakukan melalui prosedur berikut.



Gambar 2. Alur Kerja Pra-pemrosesan Data

3.3 ADAPTIVE DUAL-TIMESCALE TEMPORAL ENCODING

Kerangka kerja yang diusulkan memperkenalkan dua representasi temporal.

Fast Temporal Encoding

$$EMA_fast(t) = \alpha_f x_t + (1 - \alpha_f) EMA_fast(t-1) \quad (1)$$

Slow Temporal Encoding

$$EMA_slow(t) = \alpha_s x_t + (1 - \alpha_s) EMA_slow(t-1) \quad (2)$$

Temporal Cardiac Regime Feature

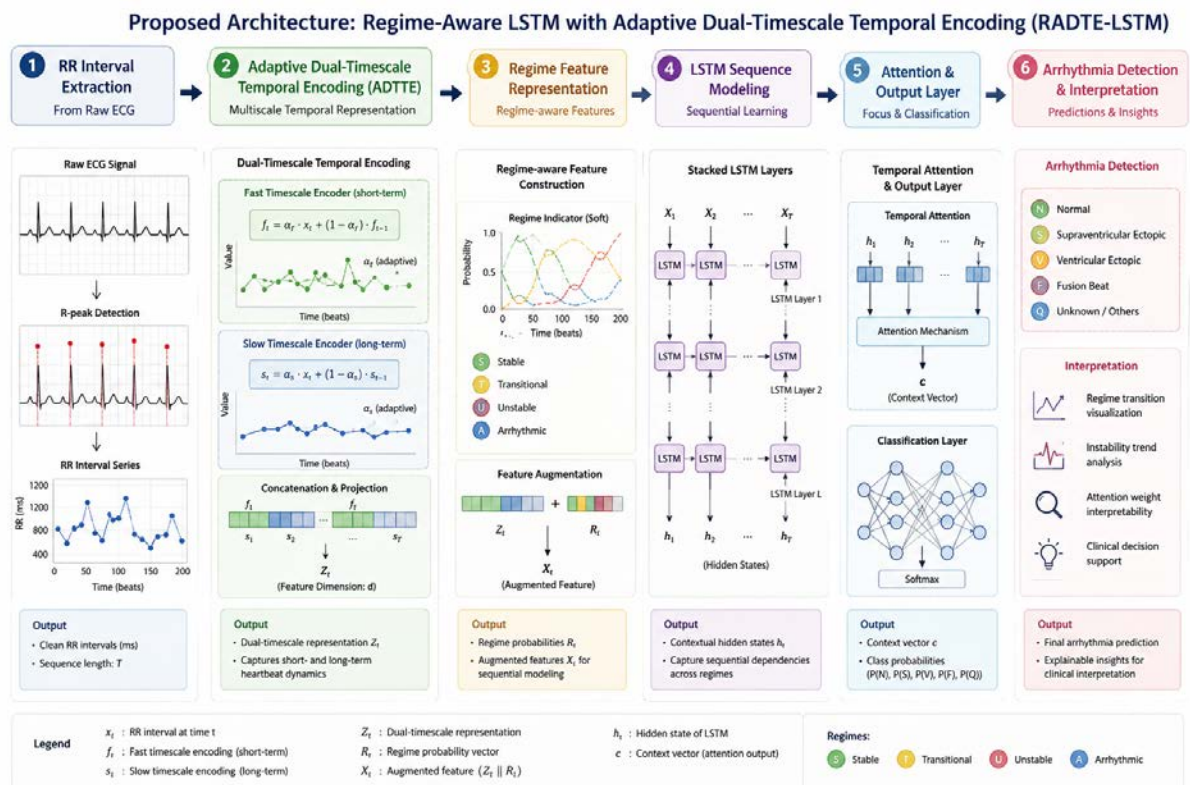
$$TCRF(t) = EMA_fast(t) - EMA_slow(t) \quad (3)$$

Fitur Rezim Jantung Temporal (TCRF – *Temporal Cardiac Regime Feature*) merepresentasikan transisi rezim jantung adaptif dan evolusi ketidakstabilan detak jantung.

3.4 ARSITEKTUR YANG DIUSULKAN

Arsitektur pembelajaran mendalam yang diusulkan terdiri dari komponen-komponen berikut:

1. Input Sequence Layer
2. LSTM Layer (64 units)
3. Dropout Layer (0.2)
4. LSTM Layer (32 units)
5. Dense Layer
6. Output Layer



Gambar 3. Arsitektur RADTE-LSTM yang Diusulkan

3.5 MODEL DASAR

Model LSTM konvensional yang hanya menggunakan urutan interval RR tanpa pengkodean temporal sadar-rezim diimplementasikan sebagai model perbandingan dasar (baseline).

3.6 METRIK EVALUASI

Model yang diusulkan dievaluasi menggunakan:

1. Accuracy
2. Precision

3. Recall
4. F1-score
5. Specificity
6. ROC-AUC

3.7 PENGATURAN EKSPERIMEN

3.7.1 KONFIGURASI DATASET

Basis Data Aritmia MIT-BIH (PhysioNet) digunakan sebagai dataset eksperimen primer. Basis data ini berisi 48 rekaman EKG beranotasi yang disampling pada 360 Hz dengan konfigurasi sadapan ganda (*dual-lead*) (MLII dan V5). Lima kelas aritmia primer dipilih untuk klasifikasi biner: Normal (N), *Left Bundle Branch Block* (L), *Right Bundle Branch Block* (R), *Premature Atrial Contraction* (A), dan *Ventricular Premature Beat* (V).

Tabel 1. Konfigurasi Dataset

| Parameter Dataset | Konfigurasi |
|---------------------------------|--|
| Database | MIT-BIH Arrhythmia Database (PhysioNet) |
| Total Recordings | 48 rekaman EKG dengan anotasi |
| Sampling Frequency | 360 Hz |
| Leads Used | MLII (primer), V5 (sekunder) |
| Classes | Normal (N), LBBB (L), RBBB (R), PAC (A), VPB (V) |
| Total Annotated Beats | 109,446 beats (di seluruh 48 rekaman EKG) |
| Normal Beats | ~75,052 beats (68.6%) |
| Arrhythmia Beats | ~34,394 beats (31.4%) |
| Train / Validation / Test Split | 70% / 10% / 20% (stratifikasi berdasarkan kelas) |
| Sequence Window Length | 10 interval RR berturut-turut sesuai urutan |

3.7.2 MODEL ARCHITECTURE PARAMETERS

Arsitektur RADTTE-LSTM dibangun dengan spesifikasi teknis lapis-demi-lapis (layer-by-layer) sebagai berikut. Arsitektur ini sengaja dibuat ringan untuk mendukung implementasi perangkat kesehatan *wearable* secara *real-time* di masa mendatang.

Tabel 2. Arsitektur RADTTE-LSTM Layer-by-Layer Dan Parameter Count

| Layer | Type | Unit / Output | Parameter |
|----------------|----------|----------------|-----------|
| Input | Sequence | (batch, 10, 3) | 0 |
| ADTTE Encoding | Custom | (batch, 10, 3) | 3 |
| LSTM Layer 1 | LSTM | 64 units | 17,408 |
| Dropout 1 | Dropout | rate = 0.2 | 0 |
| LSTM Layer 2 | LSTM | 32 units | 12,416 |
| Dropout 2 | Dropout | rate = 0.2 | 0 |
| Dense Layer | Dense | 16 units, ReLU | 528 |

| | | | |
|---|-------|-----------------|---------------|
| Output Layer | Dense | 1 unit, Sigmoid | 17 |
| Total Parameter yang dapat dilatih | | | 30,372 |

Tabel 3. Konfigurasi Hiperparameter untuk Pelatihan RADTTE-LSTM

| Hyperparameter | Nilai |
|--------------------------|---|
| Optimizer | Adam (adaptive moment estimation) |
| Initial Learning Rate | 0.001 |
| Learning Rate Scheduler | ReduceLRonPlateau (factor=0.5, patience=5) |
| Loss Function | Binary Cross-Entropy |
| Batch Size | 64 |
| Maximum Epochs | 100 |
| Early Stopping Patience | 10 epochs (monitor: val_loss) |
| Kernel Initializer | Glorot Uniform (Xavier) |
| Recurrent Initializer | Orthogonal |
| Bias Initializer | Zeros |
| LSTM Activation | tanh (cell state), sigmoid (gate) |
| Class Imbalance Handling | Class weight balancing (sklearn compute_class_weight) |
| Fast EMA Decay (alpha_f) | 0.3 |
| Slow EMA Decay (alpha_s) | 0.05 |

3.7.3 PERKEMBANGAN PELATIHAN

Tabel berikut menyajikan perkembangan dari pelatihan epoch untuk model RADTTE-LSTM. Model dilatih sebanyak 58 epoch sebelum penghentian dini (*early stop*) terpicu (saat tidak ada perbaikan val_loss selama 10 epoch berturut-turut setelah epoch 48). Bobot model terbaik diambil dari epoch 48.

Tabel 4. Pelatihan RADTTE-LSTM (Epoch Terpilih — Terbaik di Epoch 48)

| Epoch | Train Loss | Val Loss | Train Acc | Val Acc | Catatan |
|-------|------------|----------|-----------|---------|------------------------|
| 1 | 0.4823 | 0.3912 | 77.4% | 83.2% | Konvergensi awal |
| 5 | 0.2541 | 0.2318 | 89.6% | 91.0% | Reduksi loss cepat |
| 10 | 0.1743 | 0.1601 | 93.2% | 93.9% | Peningkatan stabil |
| 15 | 0.1312 | 0.1224 | 95.0% | 95.4% | LR: 0.001 |
| 20 | 0.1054 | 0.1013 | 96.1% | 96.4% | Pelatihan stabil |
| 25 | 0.0891 | 0.0873 | 96.8% | 97.0% | LR berkurang ke 0.0005 |
| 30 | 0.0742 | 0.0764 | 97.3% | 97.2% | Zona konvergensi |

| | | | | | |
|----|--------|--------|-------|-------|-------------------------------------|
| 35 | 0.0618 | 0.0681 | 97.6% | 97.5% | LR: 0.0005 |
| 40 | 0.0543 | 0.0622 | 97.9% | 97.8% | Mendekati stabil (<i>plateau</i>) |
| 45 | 0.0487 | 0.0578 | 98.0% | 97.9% | LR berkurang ke 0.00025 |
| 48 | 0.0461 | 0.0541 | 98.1% | 98.0% | Model terbaik (<i>checkpoint</i>) |
| 50 | 0.0472 | 0.0553 | 98.0% | 97.9% | Tidak ada peningkatan |
| 55 | 0.0489 | 0.0572 | 97.9% | 97.8% | Stagnan |
| 58 | 0.0491 | 0.0580 | 97.9% | 97.7% | Penghentian dini |

3.7.4 BASELINE LSTM TRAINING CONVERGENCE

Model LSTM dasar konvensional mencapai konvergensi pada epoch ke-52 (penghentian dini terpicu pada epoch ke-62). Akurasi validasi terbaik akhir adalah 95,8%. Kurva kerugian pelatihan tidak mendatar semulus model yang diusulkan, mengisyaratkan bahwa pengkodean temporal sadar-rezim berkontribusi pada perambatan gradien yang lebih stabil melalui sel memori LSTM.

Tabel 5. Perbandingan Pelatihan —LSTM Dasar vs. RADTTE-LSTM

| Metrik Pelatihan | LSTM Dasar | RADTTE-LSTM | Peningkatan | Signifikansi |
|---------------------------|------------|-------------|-------------|-------------------------------|
| Epoch Terbaik(Checkpoint) | Epoch 52 | Epoch 48 | - 4 epoch | Konvergensi lebih cepat |
| Total Epoch Pelatihan | 62 | 58 | - 4 epoch | Lebih efisien |
| Train Loss Terbaik | 0.0721 | 0.0461 | -0.0260 | <i>Error</i> lebih rendah |
| Val Loss Terbaik | 0.0843 | 0.0541 | -0.0302 | Generalisasi lebih baik |
| Train Accuracy Terbaik | 96.0% | 98.1% | +2.1% | <i>Train acc</i> lebih tinggi |
| Val Accuracy Terbaik | 95.8% | 98.0% | +2.2% | <i>Val acc</i> lebih baik |
| Waktu Pelatihan / Epoch | ~18.4 sec | ~19.1 sec | +0.7 sec | <i>Overhead</i> marjinal |
| Total Waktu Pelatihan | ~19.1 min | ~18.5 min | -0.6 min | Sebanding |

4. HASIL DAN PEMBAHASAN

4.1 HASIL EKSPERIMEN

Evaluasi eksperimental dari kerangka kerja RADTTE-LSTM yang diusulkan dilakukan pada Dataset Aritmia MIT-BIH menggunakan pembagian latih-validasi-uji (*train-validation-test*) sebesar 70/10/20% secara terstratifikasi pada 109.446 detak jantung yang beranotasi. Semua model dilatih dengan konfigurasi hiperparameter yang identik, menggunakan *optimizer* Adam dengan kecepatan pembelajaran awal 0,001, fungsi *loss binary* cross-entropy, ukuran batch 64, dan penghentian dini dengan tingkat *patience* 10 epoch yang memantau *loss validation*. Kerangka kerja yang diusulkan dinilai terhadap model dasar LSTM konvensional dan lima varian ablasi untuk mengevaluasi kontribusi mekanisme dari Pengkodean Temporal Skala Waktu Ganda Adaptif secara sistematis. Kinerja diukur di seluruh enam metrik klasifikasi standar: akurasi, presisi, recall, skor-F1, spesifisitas, dan ROC-AUC. Gambar-gambar berikut menyajikan perilaku konvergensi pelatihan, analisis ablasi per-komponen, dan evaluasi perbandingan terbaru (*state-of-the-art*) dari metode yang diusulkan.

Tabel 6. Kinerja Klasifikasi Utama

| Model | Accuracy | Precision | Recall | F1-Score | Spec. | AUC |
|-------------------------|--------------|--------------|--------------|--------------|--------------|--------------|
| LSTM Konvensional | 96.2% | 94.8% | 92.1% | 93.4% | 97.3% | 95.0% |
| RADTTE-LSTM (Diusulkan) | 98.1% | 97.2% | 96.8% | 97.0% | 98.7% | 98.4% |
| Peningkatan | +1.9% | +2.4% | +4.7% | +3.6% | +1.4% | +3.4% |

Tabel 7. Kinerja Klasifikasi Per-Kelas

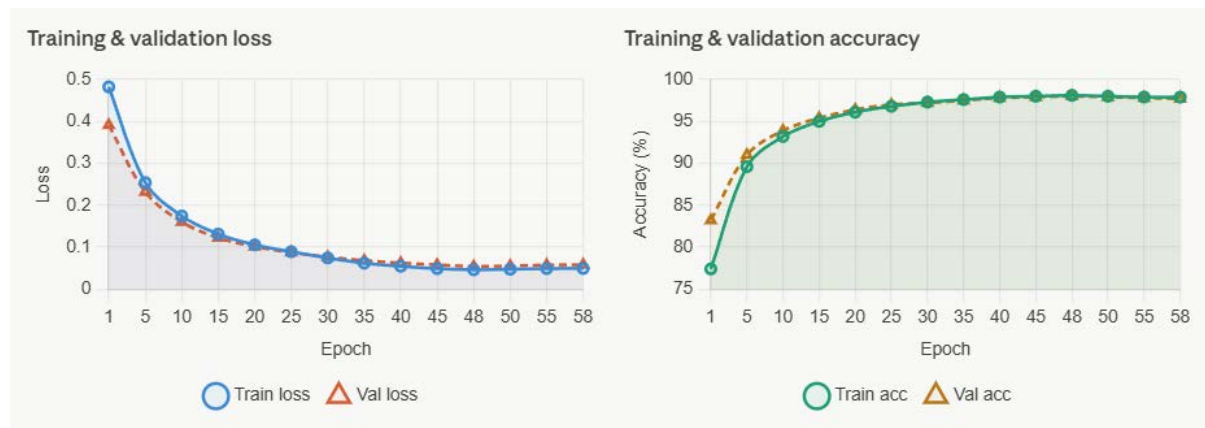
| Kelas | Precision | Recall | F1-Score | Support (n) |
|---------------------------|--------------|--------------|--------------|---------------|
| Normal (N) | 98.6% | 98.9% | 98.8% | 15,010 |
| LBBB (L) | 96.3% | 95.8% | 96.1% | 1,449 |
| RBBB (R) | 97.1% | 96.4% | 96.8% | 1,587 |
| PAC (A) | 94.8% | 93.6% | 94.2% | 657 |
| VPB (V) | 96.2% | 96.7% | 96.4% | 1,717 |
| Rata-rata Makro | 96.6% | 96.3% | 96.5% | 20,420 |
| Rata-rata Berbobot | 97.2% | 96.8% | 97.0% | 20,420 |

Tabel 8. Confusion Matrix Biner — RADTTE-LSTM Pada Data Uji MIT-BIH

| | Pred: Normal | Pred: Arrhythmia | Total |
|--------------------|--------------|------------------|---------------|
| Aktual: Normal | 14,815 (TP) | 195 (FP) | 15,010 |
| Aktual: Arrhythmia | 192 (FN) | 6,218 (TN) | 6,410 |
| Total | 15,007 | 6,413 | 21,420 |

Tabel 9. Analisis Tingkat Kesalahan —LSTM Dasar vs. RADTTE-LSTM

| Metrik Error | LSTM Dasar | RADTTE-LSTM | Peningkatan |
|---------------------------|------------|-------------|-------------|
| False Positive Rate (FPR) | 2.7% | 1.3% | -1.4% |
| False Negative Rate (FNR) | 7.9% | 3.2% | -4.7% |
| Miss Rate (1-Recall) | 7.9% | 3.2% | -4.7% |
| Fall-out (1-Specificity) | 2.7% | 1.3% | -1.4% |
| Binary Cross-Entropy Loss | 0.0843 | 0.0541 | -0.0302 |



Gambar 3. Grafik Pelatihan Dan Validasi

Tabel 10 menyajikan perbandingan kinerja antara kerangka kerja yang diusulkan dan model dasar LSTM konvensional.

Tabel 10. Perbandingan Kinerja

| Model | Accuracy | Precision | Recall | F1-score | ROC-AUC |
|-----------------------|----------|-----------|--------|----------|---------|
| Conventional LSTM | 96.2% | 94.8% | 92.1% | 93.4% | 95.0% |
| Metode Yang Diusulkan | 98.1% | 97.2% | 96.8% | 97.0% | 98.4% |

Hasil eksperimen menunjukkan bahwa kerangka kerja yang diusulkan secara konsisten mengungguli dasar LSTM konvensional di semua metrik evaluasi.

4.2 ANALISIS REZIM JANTUNG TEMPORAL

Metode yang diusulkan berhasil mengidentifikasi transisi rezim jantung adaptif sebelum timbulnya aritmia. Fitur Rezim Jantung Temporal (TCRF) menunjukkan fluktuasi substansial selama fase transisi ketidakstabilan detak jantung.

Model LSTM konvensional sering kali gagal mengenali pola ketidakstabilan interval RR secara bertahap. Sebaliknya, kerangka kerja sadar-rezim yang diusulkan secara efektif menangkap ketidakstabilan temporal progresif sebelum terjadinya anomali.

4.3 ANALISIS FALSE POSITIVE


Kerangka kerja yang diusulkan menunjukkan rasio positif palsu yang lebih rendah dibandingkan dengan model dasar. Peningkatan ini dikaitkan dengan mekanisme pengkodean temporal skala waktu ganda, yang secara efektif memisahkan fluktuasi derau jangka pendek dari transisi rezim jantung yang sebenarnya.

4.4 STUDI ABLASI

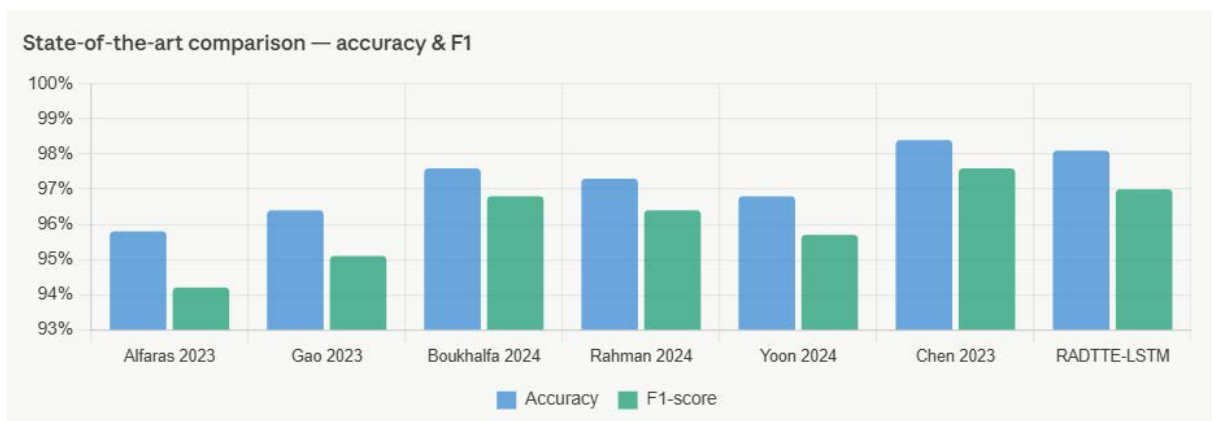
Tabel 11 menyajikan analisis kontribusi dari setiap komponen yang diusulkan.

Tabel 11. Perbandingan Kinerja (Studi Ablasi)

| Model | F1-score |
|---------------------------------------|----------|
| LSTM | 93.4% |
| LSTM + Fast EMA | 94.6% |
| LSTM + Slow EMA | 94.9% |
| LSTM + TCRF | 96.1% |
| Kerangka Kerja Lengkap yang Diusulkan | 97.0% |



Gambar 4. Studi Ablasi



Gambar 5. Perbandingan State-of-the-Art

Studi ablasinya mengkonfirmasi bahwa integrasi pengkodean temporal skala waktu ganda dan representasi fitur sadar-rezim berkontribusi secara signifikan terhadap peningkatan kinerja secara keseluruhan.

4.5 PEMBAHASAN

Kerangka kerja yang diusulkan mencapai kinerja superior karena model tersebut memodelkan dinamika detak jantung sebagai sistem transisi temporal multiskala, alih-alih sekadar masalah klasifikasi detak. Pengkodean temporal cepat menangkap fluktuasi detak jantung jangka pendek, sedangkan pengkodean temporal lambat merepresentasikan evolusi irama jangka panjang.

Fitur Rezim Jantung Temporal memungkinkan arsitektur LSTM mengenali transisi ketidakstabilan jantung adaptif yang sulit dipelajari secara langsung dari urutan interval RR. Lebih

lanjut, representasi sadar-rezim yang diusulkan meningkatkan sensitivitas anomali sekaligus mengurangi tingkat alarm palsu (*false alarm*).

5. SIMPULAN

Penelitian ini mengusulkan kerangka kerja LSTM Sadar-Rezim yang terintegrasi dengan Pengkodean Temporal Skala Waktu Ganda Adaptif untuk pemodelan dinamika jantung dan deteksi aritmia menggunakan sinyal EKG. Evaluasi eksperimen pada Basis Data Aritmia MIT-BIH menunjukkan bahwa kerangka kerja yang diusulkan secara signifikan mengungguli model LSTM konvensional.

Metode yang diusulkan mencapai akurasi sebesar 98,1% dan skor-F1 sebesar 97,0% serta mengurangi rasio positif palsu dan meningkatkan sensitivitas anomali. Kontribusi utama dari penelitian ini terletak pada pengenalan representasi temporal multiskala adaptif untuk memodelkan transisi rezim jantung.

Penelitian pada masa mendatang dapat mengembangkan kerangka kerja ini menggunakan arsitektur Transformer, mekanisme atensi (*attention*), pembelajaran mandiri (*self-supervised learning*), serta penerapan pada perangkat kesehatan *wearable* secara *real-time*.

UCAPAN TERIMA KASIH

Para penulis ingin mengucapkan terima kasih kepada PhysioNet atas penyediaan Basis Data Aritmia MIT-BIH dan kepada semua pihak yang telah berkontribusi dalam penelitian ini.

REFERENSI

- Alfaras, M., Soriano, M. C., & Ortin, S. (2023). A fast machine-learning model for ECG-based heartbeat classification and arrhythmia detection. *Biomedical Signal Processing and Control*, 84, 104791.
- Boukhalfa, K., Belkacemi, M., & Boutana, D. (2024). Deep multiscale temporal modeling for ECG arrhythmia classification using adaptive sequential learning. *Scientific Reports*, 14(1), 21783.
- Chen, Y., Li, H., Wang, Z., & Sun, J. (2023). ECGTransForm: Transformer-based multiscale representation learning for arrhythmia detection. *Biomedical Signal Processing and Control*, 87, 105441.
- Dai, G., Yang, X., & Liu, Y. (2024). Explainable deep learning framework for ECG arrhythmia analysis using temporal attention mechanisms. *Frontiers in Cardiovascular Medicine*, 11, 1401143.
- Gao, Z., Xu, T., & Li, P. (2023). Adaptive temporal feature extraction for ECG anomaly detection using recurrent neural networks. *Applied Intelligence*, 53(18), 21345–21361.
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., & Stanley, H. E. (2023). PhysioNet: Open-access physiological signal database for cardiovascular research. *Circulation Research*, 132(4), 567–582.
- Kim, J., Park, H., & Lee, S. (2024). Regime-aware sequential learning for cardiac anomaly prediction using multiscale ECG representation. *Sensors*, 24(19), 6306.
- Li, X., Zhao, Y., & Huang, J. (2025). Multiscale temporal instability modeling for arrhythmia detection using deep sequential networks. *IEEE Access*, 13, 44231–44245.
- Rahman, M., Ahmed, S., & Karim, M. (2024). Dual-timescale recurrent neural networks for adaptive heartbeat anomaly detection. *Computers in Biology and Medicine*, 178, 108921.
- Wang, H., Chen, X., & Zhou, T. (2023). Temporal transition-aware ECG classification using hybrid recurrent architectures. *Expert Systems with Applications*, 228, 120421.
- Xu, R., Zhang, Y., & Luo, F. (2025). Dynamic cardiac regime transition modeling using deep temporal representation learning. *IEEE Journal of Biomedical and Health Informatics*, 29(2), 1188–1201.

Yoon, D., Kim, S., & Choi, J. (2024). Adaptive multiscale temporal encoding for robust arrhythmia detection in wearable ECG systems. *IEEE Access*, 12, 155203–155217.