

**IMPLEMENTASI STATIONARY WAVELET TRANSFORM DAN
ARSTEKTUR DENSENET-LONG SHORT-TERM MEMORY
PADA KLASIFIKASI BEAT SINYAL
ELEKTROKARDIOGRAM**

SKRIPSI

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
Sarjana Matematika**

**Oleh:
CITRA PERTIWI
08011382126104**



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA
2025**

LEMBAR PENGESAHAN

**IMPLEMENTASI STATIONARY WAVELET TRANSFORM DAN
ARSITEKTUR DENSENET-LONG SHORT-TERM MEMORY PADA
KLASIFIKASI BEAT SINYAL ELEKTROKARDIOGRAM**

SKRIPSI

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
Sarjana Matematika**

Oleh

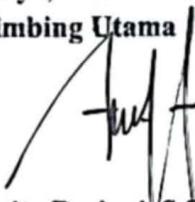
**CITRA PERTIWI
NIM. 08011382126104**

Pembimbing Kedua

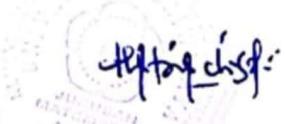

Dr. Yuli Andriani, S.Si., M.Si
NIP. 197207021999032001

Indralaya, 18 Maret 2025

Pembimbing Utama


Dr. Anita Desiani, S.Si., M.Kom.
NIP. 197712112008122002

Mengetahui,
Ketua Jurusan Matematika


Dr. Dian Cahyawati Sukanda, S.Si., M.Si
NIP. 197303212000122001

HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Citra Pertwi
NIM : 08011382126104
Jurusan : Matematika
Fakultas : Matematika dan Ilmu Pengetahuan Alam

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai pemenuhan persyaratan untuk memperoleh gelar kesarjanaan strata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain. Semua informasi yang dimuat dalam skripsi ini berasal dari penulis lain baik yang dipublikasikan atau telah diberikan penghargaan dengan mengutip nama sumber penulis secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, 18 Maret 2025

Penulis



Citra Pertwi

NIM. 08011382126104

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk :

Yang MahaKuasa Allah Subhanahu Wa Ta'ala,

Orang tuaku yang sangat kucinta,

Kakak-kakakku tersayang,

Adik tersayang,

Keluarga Besarku,

Semua Guru dan Dosenku,

Teman baik yang Kubanggakan,

Almamaterku

Motto

"Jika jalan yang mudah tidak ada, ciptakan jalanmu sendiri"

-Eren Yeager, Attack on Titan

KATA PENGANTAR

Puji syukur atas kehadirat Allah *Subhanahu Wa Ta'ala* yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi berjudul “*Implementasi Stationary Wavelet Transform dan Arsitektur DenseNet-Long Short-Term Memory Pada Klasifikasi Beat Sinyal Elektrokardiogram*”. Skripsi ini ditulis sebagai salah satu syarat memperoleh gelar sarjana sains studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa skripsi ini tidak mungkin terselesaikan tanpa adanya semangat, dukungan, bantuan, bimbingan dan nasihat yang diberikan berbagai pihak selama proses penyusunan ini berlangsung. Penulis mengucapkan terima kasih yang sebesar-besarnya kepada orang tua tercinta, Ayahku **Makmur Mahmud** dan ibuku **Novita** yang tidak pernah berhenti berjuang dan memberikan yang terbaik untukku sebagai putrinya, terkhusus Ibuku **Novita** yang sudah melahirkan dan memberikan do'a serta pengajaran terbaik kepadaku. Terima kasih karena tak pernah lelah mendidik, menasehati, membimbing, mendukung dan terus mendo'akan. Saudara-saudaraku tersayang, **Aris Munandar, Fitri Rahmawati, Nabila Nurjannah, Angga Budiawan** dan **Yuni Tiara** yang senantiasa memberikan semangat dan doa terbaik untuk penulis. Penulis juga ingin menyampaikan ucapan terima kasih kepada sebesar-besarnya dan penghargaan setinggi-tingginya kepada:

1. Bapak **Prof. Hermansyah, S.Si., M.Si., Ph.D** selaku Dekan Fakultas MIPA Universitas Sriwijaya. Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Ketua Jurusan Matematika serta Ibu **Des Alwine Zayanti, S.Si., M.Si.** selaku

Sekretaris Jurusan Matematika yang telah membimbing dan mengarahkan dalam urusan akademik selama menempuh perkuliahan di Jurusan Matematika FMIPA Universitas Sriwijaya.

2. Ibu **Dr. Anita Desiani, S.Si., M.Kom** selaku Dosen Pembimbing Utama dan Ibu **Dr. Yuli Andriani, S.Si., M.Si.** selaku Dosen Pembimbing Kedua sekaligus Dosen Pembimbing Akademik yang telah bersedia meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan, arahan dan didikan yang berharga selama pembuatan skripsi, perlombaan dan proses perkuliahan.
3. Bapak **Drs. Ali Amran, M.T** dan Ibu **Sri Indra Maiyanti, S.Si, M.Si.** selaku Dosen Pembahas yang telah meluangkan waktunya dalam memberikan tanggapan, saran, masukan, dan kritik yang sangat bermanfaat untuk perbaikan dan penyelesaian draft skripsi ini.
4. **Seluruh Dosen di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya** yang telah memberikan ilmu yang sangat bermanfaat bagi penulis. Bapak **Irwansyah** dan Ibu **Hamidah** selaku staf administrasi di Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu penulis selama perkuliahan.
5. **Kakak-kakak tingkat dan adik-adik tingkat bidang komputasi, Tim Komputasi 2021, Asisten Laboratorium Komputasi FMIPA** dan **Keluraga Matematika 2021** yang telah membantu serta berbagi ilmu selama proses perkuliahan. Terima kasih untuk bantuan, semangat dan kerja samanya. **Himpunan Mahasiswa Matematika (HIMASTIK)** yang telah menjadi wadah bagi mahasiswa untuk berkembang baik dalam bidang

akademik maupun non-akademik. Partner **Tim Sinyal, Annisa Aulia Lestari** dan **Tri Febriani Putri** yang telah berjuang bersama dan saling bertukar pikiran selama proses skripsi ini.

6. Semua pihak yang tidak dapat penulis sebutkan satu per satu, semoga semua kebaikan yang telah diberikan mendapatkan balasan dari Allah.

Semoga skripsi ini dapat menambah pengetahuan dan bermanfaat bagi mahasiswa/i Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya dan semua pihak yang membutuhkan.

Indralaya, Maret 2025

Penulis

**IMPLEMENTATION OF STATIONARY WAVELET TRANSFORM AND
DENSENET-LONG SHORT-TERM MEMORY ARCHITECTURES ON
BEAT CLASSIFICATION OF ELECTROCARDIOGRAM SIGNALS**

By :

Citra Pertiwi

08011382126104

ABSTRACT

ECG signal recordings are used to diagnose various heart conditions. Diagnosis of heart abnormalities in ECG signal recordings is done by classifying the heartbeat rhythm into 5 classes, namely non ectopic beat (N), supraventricular ectopic beats (S), ventricular ectopic beats (V), fusion beat (F) and unknown beat (Q). This research will combine the preprocessing stage using Stationary Wavelet Transform (SWT) for signal quality improvement and beat classification of ECG signals in the MIT-BIH Arrhythmia Database using a combination of DenseNet and LSTM architectures. DenseNet is used to capture features from ECG signals through direct connection between layers and LSTM is used to filter features from DenseNet according to data order through gated mechanisms. The SWT method obtained an average SNR value of 26.65 dB, indicating good signal quality with low noise. Model performance evaluation was conducted by measuring accuracy, sensitivity, specificity, precision and F1-score. The results of the performance evaluation obtained an average accuracy of 98.07%, indicating that the model can classify almost all data correctly. The average sensitivity of 95.15% shows that the model can group data that is a certain class correctly. The average specificity of 98.78% shows that the model can group data that is not a certain class correctly. The average precision of 95.17% indicates the model has excellent accuracy in predicting each class. The average F1-score of 95.1% indicates the model is very good at maintaining balance in distinguishing each class, both the class and those that do not belong to the class. The results per class in classes F, S, V, and Q were excellent in all performance evaluation metrics at more than 90%. In class N, the accuracy, specificity, and precision values were very good at more than 90%, but the sensitivity and F1-score were less than 90%. Based on this study, the proposed model provides excellent results overall, but development is needed to distinguish between normal and arrhythmic beats, as well as improvements to the architecture to increase the sensitivity and F1-score values in class N which are less than 90%.

Keywords: ECG Signal Classification, DenseNet, LSTM, Stationary Wavelet Transform, Signal-to-Noise Ratio

**IMPLEMENTASI STATIONARY WAVELET TRANSFORM DAN
ARSTEKTUR DENSENET- LONG SHORT-TERM MEMORY PADA
KLASIFIKASI BEAT SINYAL ELEKTROKARDIOGRAM**

Oleh :

Citra Pertiwi

08011382126104

ABSTRAK

Rekaman sinyal EKG digunakan untuk mendiagnosis berbagai kondisi jantung. Diagnosis kelainan jantung pada rekaman sinyal EKG dilakukan dengan cara mengklasifikasikan irama detak jantung ke dalam 5 kelas, yaitu *non ectopic beat* (N), *supraventricular ectopic beats* (S), *ventricular ectopic beats* (V), *fusion beat* (F) dan *unknown beat* (Q). Penelitian ini akan menggabungkan tahap *preprocessing* menggunakan *Stationary Wavelet Transform* (SWT) untuk perbaikan kualitas sinyal dan klasifikasi *beat* sinyal EKG pada MIT-BIH *Arrhythmia Database* menggunakan kombinasi arsitektur *DenseNet* dan LSTM. *DenseNet* digunakan untuk menangkap fitur-fitur dari sinyal EKG melalui koneksi langsung antar *layer* dan LSTM digunakan untuk menyaring fitur dari *DenseNet* sesuai urutan data melalui *gated mechanisms*. Metode SWT memperoleh rata-rata nilai SNR sebesar 26,65 dB, menunjukkan kualitas sinyal sudah baik dengan *noise* yang rendah. Evaluasi kinerja model dilakukan dengan mengukur akurasi, sensitivitas, spesifisitas, presisi dan F1-score. Hasil evaluasi kinerja diperoleh akurasi rata-rata 98,07% menunjukkan bahwa model dapat mengelompokkan hampir keseluruhan data dengan benar. Sensitivitas rata-rata 95,15% menunjukkan model dapat mengelompokkan data yang merupakan kelas tertentu dengan benar. Spesifisitas rata-rata 98,78% menunjukkan model dapat mengelompokkan data yang bukan merupakan kelas tertentu dengan benar. Presisi rata-rata 95,17% menunjukkan model memiliki ketepatan yang sangat baik dalam memprediksi setiap kelas. F1-score rata-rata 95,1% menunjukkan model sangat baik mempertahankan keseimbangan dalam membedakan setiap kelas, baik kelas tersebut maupun yang bukan termasuk kelas tersebut. Hasil per kelas pada kelas F, S, V, dan Q sangat baik pada semua metrik evaluasi kinerja yaitu lebih dari 90%. Pada kelas N nilai akurasi, spesifisitas, dan presisi sudah sangat baik yaitu lebih dari 90%, namun sensitivitas dan F1-score kurang dari 90%. Berdasarkan penelitian ini, model yang diusulkan memberikan hasil sangat baik secara keseluruhan, namun perlu dilakukan pengembangan untuk membedakan antara *beat* normal dan aritmia, serta perbaikan pada arsitektur untuk meningkatkan nilai sensitivitas dan F1-score pada kelas N yang kurang dari 90%.

Kata Kunci: Klasifikasi Sinyal EKG, *DenseNet*, LSTM, *Stationary Wavelet Transform*, *Signal-to-Noise Ratio*

DAFTAR ISI

| | |
|--|-------------|
| HALAMAN JUDUL | i |
| HALAMAN PENGESAHAN..... | ii |
| DAFTAR ISI..... | viii |
| DAFTAR TABEL | x |
| DAFTAR GAMBAR..... | xi |
| BAB I PENDAHULUAN..... | 1 |
| 1.1 Latar Belakang | 1 |
| 1.2 Perumusan Masalah..... | 8 |
| 1.3 Pembatasan Masalah | 8 |
| 1.4 Tujuan..... | 8 |
| 1.5 Manfaat..... | 9 |
| BAB II TINJAUAN PUSTAKA..... | 10 |
| 2.1 Elektrokardiogram (EKG) | 10 |
| 2.2 <i>Preprocessing Data</i> | 11 |
| 2.2.1 Segmentasi <i>Beat</i> | 12 |
| 2.2.2 <i>Stationary Wavelet Transform</i> (SWT) | 14 |
| 2.2.3 <i>Signal-to-Noise Ratio</i> (SNR)..... | 16 |
| 2.3 <i>DenseNet</i> | 17 |
| 2.3.1 <i>Convolution Layer</i> | 19 |
| 2.3.2 <i>Batch Normalization</i> | 19 |
| 2.3.3 Fungsi Aktivasi ReLU..... | 20 |
| 2.3.4 <i>Concatenate Layer</i> | 21 |
| 2.3.5 <i>Pooling Layer</i> | 22 |
| 2.3.6 <i>Long-Short Term Memory</i> | 23 |
| 2.3.7 <i>Fully Connected Layer</i> | 28 |
| 2.3.8 <i>Loss Function: Categorical Cross-Entropy</i> | 29 |
| 2.3.9 <i>Optimization Function: Adaptive Momen Estimation</i> (Adam) | 29 |
| 2.4 <i>Confusion Matrix</i> | 31 |

| | |
|---|------------|
| BAB III METODOLOGI PENELITIAN | 34 |
| 3.1 Tempat..... | 34 |
| 3.2 Waktu | 34 |
| 3.3 Alat..... | 34 |
| 3.4 Metode Penelitian..... | 34 |
| BAB IV HASIL DAN PEMBAHASAN | 42 |
| 4.1 Deskripsi Data | 42 |
| 4.2 <i>Preprocessing</i> Data | 46 |
| 4.2.1 Segmentasi <i>Beat</i> | 46 |
| 4.2.2 <i>Stationary Wavelet Transform</i> (SWT) | 52 |
| 4.2.3 <i>Signal-to-Noise Ratio</i> (SNR)..... | 61 |
| 4.3 Implementasi Kombinasi Arsitektur <i>DenseNet</i> dan LSTM | 63 |
| 4.4 Operasi Manual pada <i>DenseNet</i> dan LSTM..... | 65 |
| 4.5 Hasil..... | 94 |
| 4.5.1 Hasil Implementasi <i>Stationary Wavelet Transform</i> (SWT)..... | 95 |
| 4.5.2 Hasil Implementasi Kombinasi Arsitektur <i>DenseNet</i> dan LSTM..... | 97 |
| 4.5.2.1 <i>Training</i> | 97 |
| 4.5.2.2 <i>Testing</i> | 101 |
| 4.5.2.3 Evaluasi | 105 |
| 4.6 Pembahasan dan Interpretasi Hasil..... | 115 |
| 4.6.1 Perbaikan Kualitas Sinyal | 115 |
| 4.6.2 Kombinasi Arsitektur <i>DenseNet</i> dan LSTM | 116 |
| BAB V KESIMPULAN DAN SARAN..... | 118 |
| 5.1 Kesimpulan..... | 118 |
| 5.2 Saran..... | 119 |
| DAFTAR PUSTAKA | 120 |

DAFTAR TABEL

| | |
|---|-----|
| Tabel 2.1 Kategori Nilai SNR | 17 |
| Tabel 2.2 <i>Confusion Matrix</i> | 31 |
| Tabel 2.3 Kategori Nilai Evaluasi Kinerja Model | 33 |
| Tabel 4.1 Data Sampel Titik Sinyal MIT-BIH <i>Arrhythmia Database</i> | 42 |
| Tabel 4.2 Titik R Pasien Kode 102 dan 103 MIT-BIH <i>Arrhythmia Database</i> | 43 |
| Tabel 4.3 Anotasi <i>Beat</i> EKG pada MIT-BIH <i>Arrhythmia Database</i> | 43 |
| Tabel 4.4 Non-anotasi <i>Beat</i> EKG pada MIT-BIH <i>Arrhythmia Database</i> | 44 |
| Tabel 4.5 Simbol Pasien Kode 102 dan 103 MIT-BIH <i>Arrhythmia Database</i> | 45 |
| Tabel 4.6 Contoh Hasil Segmentasi Satu <i>Beat</i> Pasien Kode 100 dan 102..... | 47 |
| Tabel 4.7 Titik Mulai dan Titik Akhir Sampel Sinyal Pasien Kode 102 | 48 |
| Tabel 4.8 Jumlah <i>Beat</i> Seluruh Pasien Aritmia | 48 |
| Tabel 4.9 Kelas MIT-BIH <i>Arrhythmia Database</i> | 50 |
| Tabel 4.10 Jumlah <i>Beat</i> Sinyal per Kelas | 51 |
| Tabel 4.11 <i>One Hot Encoding</i> | 51 |
| Tabel 4.12 Hasil SNR Metode SWT..... | 94 |
| Tabel 4.13 <i>Confusion Mastrix</i> pada MIT-BIH <i>Arryhtmia Database</i> | 100 |
| Tabel 4.14 Hasil Evaluasi Kinerja Model MIT-BIH <i>Arrhytmia Database</i> | 113 |
| Tabel 4.15 Perbandingan Hasil Evaluasi Nilai SNR dengan Penelitian Lain..... | 114 |
| Tabel 4.16 Perbandingan Hasil Evaluasi Kinerja dengan Penelitian Lain..... | 115 |

DAFTAR GAMBAR

| | |
|--|-----|
| Gambar 2.1 Sinyal Elektrokardiogram (EKG)..... | 10 |
| Gambar 2.2 Segmentasi <i>Beat</i> Sinyal EKG..... | 12 |
| Gambar 2.3 Arsitektur <i>DenseNet</i> | 18 |
| Gambar 2.4 Fungsi Aktivasi ReLU..... | 21 |
| Gambar 2.5 <i>Concatenate Layer</i> | 22 |
| Gambar 2.6 Contoh Proses <i>Average Pooling</i> | 23 |
| Gambar 2.7 Arsitektur LSTM..... | 24 |
| Gambar 2.8 Fungsi Aktivasi <i>Sigmoid</i> | 25 |
| Gambar 4.1 <i>Sample</i> Sinyal Hasil Segmentasi <i>Beat</i> ke-1 Pasien Kode 100 (a) Nilai Amplitudo dan Titik Sinyal Indeks 280-320 (b) Nilai Amplitudo dan Titik Sinyal pada Garis Orange..... | 53 |
| Gambar 4.2 <i>Sample</i> Sinyal Hasil Segmentasi <i>Beat</i> ke-1 Pasien Kode 100 (a) Sebelum dan (b) Setelah di Terapkan <i>Stationary Wavelet Transform</i> | 59 |
| Gambar 4.3 <i>Sample</i> Sinyal Hasil Segmentasi <i>Beat</i> ke-1 Pasien Kode 100 Setelah di Terapkan <i>Stationary Wavelet Transform</i> (a) Nilai Amplitudo dan Titik Sinyal Indeks 280-320 (b) Nilai Amplitudo dan Titik Sinyal pada Garis Orange | 60 |
| Gambar 4.4 Kombinasi Arsitektur <i>DenseNet</i> dan LSTM | 64 |
| Gambar 4.5 Proses <i>Concatenate Layer</i> | 72 |
| Gambar 4.6 Proses <i>Average Pooling</i> | 75 |
| Gambar 4.7 Ilustrasi <i>Fully Connected Layer</i> | 85 |
| Gambar 4.8 <i>Training</i> Model Kombinasi Arsitektur <i>DenseNet</i> dan LSTM pada MIT-BIH <i>Arrhythmia Database</i> | 97 |
| Gambar 4.9 Grafik Akurasi Proses <i>Training</i> | 98 |
| Gambar 4.10 Grafik <i>Loss</i> Proses <i>Training</i> | 99 |
| Gambar 4.11 Grafik Perbandingan Nilai Evaluasi Kinerja Model | 113 |

BAB I

PENDAHULUAN

1.1 Latar Belakang

Rekaman sinyal EKG merupakan alat yang dapat digunakan untuk mendiagnosis berbagai kondisi jantung, termasuk gangguan irama jantung yang abnormal seperti aritmia (Rahman *et al.*, 2022). Diagnosis kelainan jantung pada rekaman sinyal EKG dapat dilakukan dengan cara mengklasifikasikan irama detak jantung kedalam lima kelas, yang terdiri dari satu kelas normal dan empat kelas abnormal. Kelas normal yaitu *non ectopic beat* (N), dimana irama jantung tidak menunjukkan adanya gangguan atau stabil. Kelas abnormal terdiri dari *supraventricular ectopic beats* (S) yaitu gangguan yang berasal dari bagian atas jantung (atrium), *ventricular ectopic beats* (V) yaitu gangguan yang berasal dari bilik jantung (ventrikel), *fusion beat* (F) yaitu kombinasi antara irama detak jantung normal dan abnormal, dan *unknown beat* (Q) yaitu irama detak jantung yang tidak teridentifikasi dengan jelas atau tidak diketahui sumbernya.

Klasifikasi adalah proses pengelompokan data ke dalam kategori atau kelas tertentu yang telah ditentukan, berdasarkan atribut atau karakteristik dari data tersebut (Xu *et al.*, 2020). Klasifikasi sinyal EKG dapat dilakukan dengan memanfaatkan Metode *Deep Learning* (Ebrahimi *et al.*, 2020). Metode *Deep Learning* untuk melakukan klasifikasi sinyal EKG dapat menggunakan arsitektur *DenseNet*. *DenseNet* merupakan arsitektur yang struktur utamanya terdiri dari beberapa *Dense-Block* dan *Transition Layer* (Sitompul & Rosnelly, 2023). *Dense-Block* merupakan blok jaringan dimana setiap *layer* menerima *input* dari semua

layer sebelumnya dan mengirimkan *output* ke semua *layer* berikutnya (Cui *et al.*, 2020). Pada *Dense-Block*, fitur-fitur akan digabungkan dari berbagai lapisan, sehingga semua fitur yang sudah diproses akan dipanggil kembali tanpa seleksi dan *output*-nya kemudian diteruskan ke *Transition Layer* (Darmawahyuni *et al.*, 2019). *Transition Layer* merupakan lapisan yang ditempatkan setelah *Dense-Block* dan berfungsi untuk mereduksi dimensi fitur agar ukuran *input* pada *Dense-Block* tetap sama pada setiap lapisan (Huang *et al.*, 2020). Proses reduksi dimensi fitur pada *Transition Layer* dilakukan tanpa mempertimbangkan hubungan antar fitur, sehingga beberapa fitur yang dihasilkan dapat bersifat redundan atau terduplicasi (Hadiyoso *et al.*, 2023). *DenseNet* memiliki kelebihan yaitu dapat mengatasi masalah *vanishing gradient* melewati koneksi langsung antar *layer*, dimana setiap *layer* menerima informasi langsung dari semua *layer* sebelumnya (Ryu *et al.*, 2021). Masalah *vanishing gradient* terjadi saat nilai *gradient* mengecil secara bertahap mendekati nol karena setiap lapisan hanya menerima dan meneruskan informasi dari satu lapisan sebelumnya, sehingga setiap kali informasi diteruskan, nilainya akan semakin kecil dan lapisan awal kekurangan fitur karena hanya dapat memanggil informasi dari satu lapisan sebelumnya (Ullah *et al.*, 2021; Noh, 2021). Selain dapat mengatasi masalah *vanishing gradient*, *DenseNet* juga lebih efisien dalam penggunaan parameter karena fitur yang diekstraksi pada setiap *layer* dapat digunakan kembali oleh *layer-layer* berikutnya, sehingga *DenseNet* tidak memerlukan banyak parameter (Li *et al.*, 2021).

Penelitian Guo *et al.* (2019) menerapkan kombinasi arsitektur *DenseNet* dan GRU untuk klasifikasi sinyal EKG pada *dataset* aritmia dengan rata-rata akurasi 90,35%, spesifitas 95,15%, namun nilai sensitivitas masih 69,35% dan hanya melakukan klasifikasi 2 kelas yaitu *supraventricular ectopic beats* (S) dan *ventricular ectopic beats* (V). Rai *et al.* (2023) menerapkan arsitektur *DenseNet* dengan *Transfer Learning* untuk klasifikasi sinyal EKG pada *dataset* aritmia dengan hasil rata-rata akurasi 98,56%, presisi 98,28% dan f1-score 98,28%, namun hanya melakukan klasifikasi 2 kelas yaitu normal dan aritmia. Ullah *et al.* (2022) menerapkan arsitektur *DenseNet* untuk klasifikasi sinyal EKG pada *dataset* aritmia dengan rata-rata akurasi 99,80%, presisi 98,34%, dan f1-score 98,91%, namun hanya melakukan klasifikasi 4 kelas yaitu *non ectopic beat* (N), *supraventricular ectopic beats* (S), *ventricular ectopic beats* (V), dan *fusion beat* (F).

Input pada arsitektur *DenseNet* sangat dipengaruhi oleh kualitas data. Kualitas data yang kurang baik dapat menyebabkan model kesulitan dalam mengenali pola, sehingga proses ekstraksi fitur menjadi tidak optimal dan kualitas kinerjanya dapat menurun (Sherly & Mathivanan, 2021). Sinyal EKG sendiri sangat dipengaruhi oleh adanya *noise*. *Noise* yang tinggi dapat mengaburkan pola detak jantung serta fitur penting yang diperlukan untuk klasifikasi, sehingga model kesulitan membedakan antara irama detak jantung normal maupun abnormal dan berisiko menyebabkan terjadinya kesalahan dalam klasifikasi (Nurmaini *et al.*, 2020). *Noise* biasanya muncul akibat gangguan dari berbagai sumber, seperti gerakan tubuh pasien atau interferensi listrik dari alat elektronik

(Alimbayeva *et al.*, 2024). Metode yang dapat dilakukan untuk menangani *noise* adalah dengan menggunakan *Stationary Wavelet Transform* (SWT). SWT merupakan Metode analisis sinyal untuk menghilangkan frekuensi yang tidak diinginkan dan mendekomposisikan sinyal ke dalam beberapa level menggunakan *Low Pass Filter* (LPF) dan *High Pass Filter* (HPF) (Bouny *et al.*, 2020). LPF adalah *filter* yang menyaring frekuensi tinggi seperti *noise* untuk menangkap sinyal yang lebih halus, sedangkan HPF adalah *filter* yang menyaring frekuensi rendah untuk menangkap detail atau perubahan yang terjadi dalam sinyal (Rhif *et al.*, 2019). LPF dan HPF dapat mempertahankan detail sinyal disemua level tanpa kehilangan informasi penting, karena pengambilan sampel oleh kedua filter tersebut dilakukan tanpa mengurangi ukuran sinyal asli (Bouny *et al.*, 2020). Kualitas sinyal hasil dekomposisi dengan Metode SWT dapat diukur menggunakan *Signal-to-Noise Ratio* (SNR). Nilai SNR diatas 20 dB menunjukkan bahwa sinyal utama lebih kuat daripada *noise* (Pulavskyi *et al.*, 2019).

Penelitian Bouny *et al.* (2020) menerapkan SWT untuk perbaikan kualitas sinyal pada klasifikasi sinyal EKG dengan menggunakan arsitektur CNN. Penelitian ini menghasilkan nilai rata-rata akurasi sebesar 99,11%, sensitivitas 93,55%, dan spesifitas 99,37%, namun hanya melakukan klasifikasi 4 kelas yaitu *non ectopic beat* (N), *supraventricular ectopic beats* (S), *ventricular ectopic beats* (V), dan *fusion beat* (F). Sharma *et al.* (2023) menerapkan SWT untuk perbaikan kualitas sinyal pada klasifikasi sinyal EKG dengan menggunakan arsitektur *Bidirectional LSTM*. Penelitian ini menghasilkan nilai rata-rata akurasi sebesar 99,72%, sensitivitas 99,02%, dan spesifitas 99,82%, namun hanya

menggunakan klasifikasi dua kelas yaitu normal dan abnormal. Zhang *et al.* (2020) menerapkan SWT untuk perbaikan kualitas sinyal pada klasifikasi sinyal EKG dengan menggunakan arsitektur CNN. Penelitian ini menghasilkan nilai rata-rata akurasi sebesar 99,03%, sensitivitas 99,35%, dan spesifisitas 99,23%, namun hanya melakukan klasifikasi dua kelas yaitu aritmia dan *non-aritmia*. Sayangnya penelitian yang dilakukan oleh Bouny *et al.* (2020), Sharma *et al.* (2023) dan Zhang *et al.* (2020) tidak melakukan pengukuran nilai SNR, sehingga tidak tahu seberapa bagus SWT dalam memperbaiki kualitas sinyal pada penelitian tersebut.

EKG merupakan data berurutan yang tersusun berdasarkan urutan waktu. Setiap elemen pada data berurutan saling terhubung satu sama lain dan terus berubah seiring waktu, sehingga urutannya perlu dipertahankan agar informasi mengenai kondisi jantung yang ada pada urutan tersebut tidak hilang (Aldughayfiq *et al.*, 2023). Sayangnya, *DenseNet* tidak memiliki mekanisme yang dapat menyimpan dan mempertahankan urutan data dari waktu ke waktu. Jika data tidak diproses sesuai urutan, terutama sama *DenseNet* melakukan penggabungan fitur dari berbagai lapisan dalam *Dense Block*, urutan asli dari data bias berubah atau hilang, yang berisiko menyebabkan hilangnya informasi secara global (Huang *et al.*, 2020). Arsitektur lain pada *Deep Learning* yang dapat digunakan untuk mengelola data berurutan adalah *Long Short-Term Memory* (LSTM).

LSTM merupakan arsitektur yang mampu menyimpan dan mempertahankan urutan data dalam jangka waktu tertentu melalui *gated mechanisms* yang terdiri dari tiga struktur gerbang atau *gate*, yaitu *input gate*, *forget gate*, dan *output gate*

(Ebrahimi *et al.*, 2020). *Input gate* berguna untuk menyimpan informasi baru yang dianggap penting sesuai dengan urutan data, *forget gate* berguna untuk menghapus informasi lama yang tidak relevan tanpa merusak urutan data, dan *output gate* berguna untuk menentukan informasi mana yang akan diteruskan ke langkah berikutnya dengan tetap menjaga keutuhan urutan data (Wang *et al.*, 2020; Ma & Mao, 2021). Melalui *gated mechanisms*, LSTM dapat menyusun kembali urutan data serta menyaring fitur-fitur redundan yang diperoleh dari *DenseNet* dengan tetap mempertahankan urutan data (Zhou *et al.*, 2020). Kelemahan LSTM adalah jumlah *layer* yang terbatas, sehingga sulit mengekstraksi fitur secara detail dan mempertahankan informasi penting dalam urutan data yang sangat panjang (Qi & Mei, 2024). Semakin panjang urutan data, LSTM dapat melupakan informasi yang telah diproses sebelumnya, sehingga beberapa informasi penting dapat hilang. Berbeda dengan *DenseNet* yang memiliki banyak *layer* yang saling terhubung (*dense connections*), sehingga fitur dapat diekstraksi secara detail, dan semua informasi yang telah diproses tetap dapat dipertahankan karena informasi dari setiap *layer* sebelumnya dapat diakses kembali oleh semua *layer* berikutnya (Skydt *et al.*, 2021).

Penelitian Han *et al.* (2020) menerapkan kombinasi arsitektur CNN dan LSTM untuk klasifikasi sinyal EKG pada *dataset* aritmia. Penelitian ini menghasilkan nilai rata-rata akurasi sebesar 92,03%, namun hanya terbatas pada klasifikasi 2 kelas, yaitu normal dan aritmia. Sharma *et al.* (2020) menerapkan kombinasi arsitektur LSTM dan *Fourier-Bessel expansion* untuk klasifikasi sinyal EKG pada *dataset* aritmia dengan nilai akurasi sebesar 90,07%, namun hanya

terbatas pada klasifikasi 2 kelas yaitu normal dan abnormal. Essa & Xie (2021) menerapkan kombinasi arsitektur *Convolutional Neural Network* dan LSTM untuk klasifikasi sinyal EKG pada *dataset* aritmia dengan nilai akurasi sebesar 95,81%, spesifisitas 94,56%, namun nilai sensitivitas masih 69,20% dan hanya terbatas pada klasifikasi 3 kelas yaitu *supraventricular ectopic beats* (S), *ventricular ectopic beats* (V), dan *fusion beat* (F).

Pada penelitian ini akan menggabungkan tahap perbaikan kualitas sinyal menggunakan *Stationary Wavelet Transform* (SWT) dan mengimplementasikan kombinasi arsitektur *DenseNet* dan LSTM pada tahap klasifikasi *beat* sinyal EKG untuk *dataset* aritmia. Kombinasi arsitektur *DenseNet* dan LSTM dipilih karena *DenseNet* memiliki kemampuan dalam menangkap fitur-fitur dari sinyal EKG melalui koneksi langsung antar *layer* untuk mengurangi risiko *vanishing gradient*. Penambahan LSTM pada bagian akhir *DenseNet* digunakan untuk menyaring fitur-fitur yang redundan dengan menentukan informasi mana yang perlu disimpan, dihapus, atau diiteruskan ke langkah berikutnya sesuai dengan urutan data menggunakan *gated mechanisms*. Pada tahap perbaikan kualitas sinyal, SWT digunakan untuk menghilangkan *noise* pada rekaman sinyal EKG. Pada tahap klasifikasi, klasifikasi dibagi dalam 5 kelas, yaitu *non ectopic beat* (N), *supraventricular ectopic beats* (S), *ventricular ectopic beats* (V), *fusion beat* (F) dan *unknown beat* (Q). Keberhasilan Metode SWT untuk menghilangkan *noise*, dapat diukur kinerjanya berdasarkan nilai SNR. Keberhasilan kombinasi arsitektur *DenseNet* dapat LSTM, dapat diukur kinerjanya berdasarkan hasil akurasi, sensitivitas, spesifisitas, presisi, dan *F1-score*.

1.2 Perumusan Masalah

Perumusan masalah dalam penelitian ini adalah:

1. Bagaimana implementasi Metode SWT untuk perbaikan kualitas sinyal pada data sinyal EKG, dengan keberhasilan Metode diukur berdasarkan nilai SNR.
2. Bagaimana implementasi kombinasi arsitektur *DenseNet* dan LSTM untuk klasifikasi *beat* sinyal EKG dalam 5 kelas, dengan keberhasilan model diukur berdasarkan berbagai metrik evaluasi kinerja.

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah:

1. Modifikasi arsitektur yang diusulkan hanya melakukan klasifikasi *beat* sinyal EKG pada MIT-BIH *Arrhythmia Database* dalam 5 kelas, yaitu *non ectopic beat* (N), *supraventricular ectopic beats* (S), *ventricular ectopic beats* (V), *fusion beat* (F) dan *unknown beat* (Q).
2. Ukuran evaluasi kinerja pada tahap *preprocessing* hanya diukur menggunakan nilai SNR, sedangkan evaluasi kinerja pada kombinasi arsitektur *DenseNet* dan LSTM menggunakan akurasi, sensitivitas, spesifisitas, presisi, dan *F1-Score*.

1.4 Tujuan

Tujuan penelitian ini adalah:

1. Mengimplementasikan Metode SWT untuk perbaikan kualitas sinyal pada data sinyal EKG, dimana keberhasilan Metode akan diukur berdasarkan

nilai SNR.

2. Mengimplementasikan kombinasi arsitektur *DenseNet* dan LSTM pada klasifikasi *beat* sinyal EKG dalam 5 kelas. Keberhasilan model akan diukur berdasarkan nilai akurasi, sensitivitas, spesifisitas, presisi, dan *F1-Score*.

1.5 Manfaat

Manfaat dari penelitian ini adalah:

1. Dapat berfungsi sebagai referensi untuk penelitian perbaikan kualitas sinyal menggunakan SWT dan klasifikasi *beat* sinyal EKG menggunakan kombinasi arsitektur *DenseNet* dan LSTM.
2. Model ini dapat diterapkan untuk teknologi medis dan membantu para ahli dalam mengklasifikasikan sinyal EKG aritmia dalam 5 kelas, serta dapat diterapkan untuk klasifikasi sinyal EKG yang lain.

DAFTAR PUSTAKA

- Abdel-Nabi, H., Al-Naymat, G., Ali, M. Z., & Awajan, A. (2023). Hclsh: a novel non-linear monotonic activation function for Deep Learning methods. *IEEE Access*, 11(May), 47794–47815. <https://doi.org/10.1109/ACCESS.2023.3276298>
- Aldughayfiq, B., Ashfaq, F., Jhanjhi, N. Z., & Humayun, M. (2023). A Deep Learning approach for atrial fibrillation classification using multi-feature time series data from ECG and PPG. *Diagnostics*, 13(14), 1–25. <https://doi.org/10.3390/diagnostics13142442>
- Alimbayeva, Z., Alimbayev, C., Ozhikenov, K., Bayanbay, N., & Ozhikenova, A. (2024). Wearable ECG Device and Machine Learning for heart monitoring. *Sensors*, 24(13). <https://doi.org/10.3390/s24134201>
- Bouny, L. El, Khalil, M., & Adib, A. (2020). ECG heartbeat classification based on Multi-Scale Wavelet Convolutional Neural Networks Lahcen El Bouny , Mohammed Khalil , Abdellah Adib Laboratory of Computer Science , Faculty of Sciences and Technology , Hassan II University Of Casablanca ,. *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 3212–3216.
- Cui, B., Chen, X., & Lu, Y. (2020). Semantic Segmentation of remote sensing images using Transfer Learning and Deep Convolutional Neural Network with Dense Connection. *IEEE Access*, 8, 116744–116755. <https://doi.org/10.1109/ACCESS.2020.3003914>
- Darmawahyuni, A., Nurmaini, S., Rachmatullah, M. N., Tutuko, B., Sapitri, A. I., Firdaus, F., Fansyuri, A., & Predyansyah, A. (2022). Deep learning-based electrocardiogram rhythm and beat features for heart abnormality classification. *PeerJ Computer Science*, 8. <https://doi.org/10.7717/PEERJ-CS.825>
- Darmawahyuni, A., Nurmaini, S., Sukemi, Caesarendra, W., Bhayyu, V., Rachmatullah, M. N., & Firdaus. (2019). Deep learning with a recurrent network structure in the sequence modeling of imbalanced data for ECG-rhythm classifier. *Algorithms*, 12(6), 1–12. <https://doi.org/10.3390/a12060118>
- Desiani, A., Erwin, Maiyanti, S. I., Suprihatin, B., Rachmatullah, N., Fauza, A. N., & Ramayanti, I. (2022). R-Peak detection of beat segmentation and Convolution Neural Network for arrhythmia classification. *Journal of Engineering Science and Technology*, 17(2), 1231–1246.
- Dubey, S. R., Singh, S. K., & Chaudhuri, B. B. (2022). Activation functions in deep learning: a comprehensive survey and benchmark. *Neurocomputing*, 503, 92–108. <https://doi.org/10.1016/j.neucom.2022.06.111>

- Ebrahimi, Z., Loni, M., Daneshtalab, M., & Gharehbaghi, A. (2020). A review on deep learning methods for ECG arrhythmia classification. *Expert Systems with Applications*, 10, 7, 100033. <https://doi.org/10.1016/j.eswa.2020.100033>
- El Bouny, L., Khalil, M., & Adib, A. (2020). A wavelet denoising and teager energy operator-based method for automatic qrs complex detection in ecg signal. *Circuits, Systems, and Signal Processing*, 39(10), 4943–4979. <https://doi.org/10.1007/s00034-020-01397-8>
- Essa, E., & Xie, X. (2021a). An Ensemble of Deep Learning-Based Multi-Model for ECG heartbeats arrhythmia classification. *IEEE Access*, 9, 103452–103464. <https://doi.org/10.1109/ACCESS.2021.3098986>
- Essa, E., & Xie, X. (2021b). Multi-model Deep Learning ensemble for ECG heartbeat arrhythmia classification. *European Signal Processing Conference, 2021-Janua*, 1085–1089. <https://doi.org/10.23919/Eusipco47968.2020.9287520>
- Feng, J., Si, Y., Zhang, Y., Sun, M., & Yang, W. (2024). A high-performance anti-noise algorithm for arrhythmia recognition. <https://doi.org/10.3390/s24144558>
- Gholamalinezhad, H., & Khosravi, H. (2020). *Pooling methods in Deep Neural Networks, a review*. <http://arxiv.org/abs/2009.07485>
- Guo, L., Sim, G., & Matuszewski, B. (2019). Inter-patient ECG classification with convolutional and recurrent neural networks. *Biocybernetics and Biomedical Engineering*, 39(3), 868–879. <https://doi.org/10.1016/j.bbe.2019.06.001>
- Gupta, V., & Mittal, M. (2020). Arrhythmia detection in ECG signal using Fractional Wavelet Transform with Principal Component Analysis. *Journal of The Institution of Engineers (India): Series B*, 101(5), 451–461. <https://doi.org/10.1007/s40031-020-00488-z>
- Han, S., Lee, W., Eom, H., Kim, J., & Park, C. (2020). Detection of arrhythmia using 1D convolution neural network with LSTM model. *IEIE Transactions on Smart Processing and Computing*, 9(4), 261–265. <https://doi.org/10.5573/IEIESPC.2020.9.4.261>
- Hao, H., Liu, M., Xiong, P., Du, H., Zhang, H., Lin, F., Hou, Z., & Liu, X. (2019). Multi-lead model-based ECG signal denoising by guided filter. *Engineering Applications of Artificial Intelligence*, 79(December 2018), 34–44. <https://doi.org/10.1016/j.engappai.2018.12.004>
- Hasnul, M. A., Aziz, N. A. A., Alelyani, S., Mohana, M., & Aziz, A. A. (2021). Electrocardiogram-based emotion recognition systems and their applications in healthcare—a review. In *Sensors* (Vol. 21, Issue 15). <https://doi.org/10.3390/s21155015>
- Ho, Y., & Wookey, S. (2020). The real-world-weight cross-entropy loss function:

- modeling the costs of mislabeling. *IEEE Access*, 8, 4806–4813. <https://doi.org/10.1109/ACCESS.2019.2962617>
- Huang, W., Feng, J., Wang, H., & Sun, L. (2020). A new architecture of densely connected convolutional networks for pan-sharpening. *ISPRS International Journal of Geo-Information*, 9(4). <https://doi.org/10.3390/ijgi9040242>
- Joung, C., Kim, M., Paik, T., Kong, S. H., Oh, S. Y., Jeon, W. K., Jeon, J. H., Hong, J. S., Kim, W. J., Kook, W., Cha, M. J., & van Koert, O. (2024). Deep learning based ECG segmentation for delineation of diverse arrhythmias. *PLoS ONE*, 19(6 June), 1–21. <https://doi.org/10.1371/journal.pone.0303178>
- Kumar, A., Tomar, H., Mehla, V. K., Komaragiri, R., & Kumar, M. (2021). Stationary wavelet transform based ECG signal denoising method. *ISA Transactions*, 114, 251–262. <https://doi.org/10.1016/j.isatra.2020.12.029>
- Li, G., Zhang, M., Li, J., Lv, F., & Tong, G. (2021). Efficient densely connected convolutional neural networks. *Pattern Recognition*, 109. <https://doi.org/10.1016/j.patcog.2020.107610>
- Lin, H., Liu, R., & Liu, Z. (2023). ECG signal denoising method based on disentangled Autoencoder. *Electronics (Switzerland)*, 12(7). <https://doi.org/10.3390/electronics12071606>
- Madhu, G., Kautish, S., Alnowibet, K. A., Zawbaa, H. M., & Mohamed, A. W. (2023). NIPUNA: A novel optimizer activation function for Deep Neural Networks. *Axioms*, 12(3). <https://doi.org/10.3390/axioms12030246>
- Mishra, S., Vanli, O. A., Huffer, F. W., & Jung, S. (2016). Regularized discriminant analysis for multi-sensor decision fusion and damage detection with Lamb waves. *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016*, 9803(850), 98032H. <https://doi.org/10.1117/12.2217959>
- Nurmaini, S., Darmawahyuni, A., Mukti, A. N. S., Rachmatullah, M. N., Firdaus, F., & Tutuko, B. (2020). Deep learning-based stacked denoising and autoencoder for ECG heartbeat classification. *Electronics (Switzerland)*, 9(1), 1–17. <https://doi.org/10.3390/electronics9010135>
- Pratama, A. A., & Abadi, A. M. (2023). Classification of Arrhythmia Diseases By the Convolutional Neural Network Method based on Ecg images. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 17(2), 0625–0634. <https://doi.org/10.30598/barekengvol17iss2pp0625-0634>
- Pulavskyi, A. A., Krivenko, S. S., & Kryvenko, L. S. (2019). Determination of the signal-to-noise ratio for noisy electrocardiogram using lossless data compression. *2019 8th Mediterranean Conference on Embedded Computing, MECO 2019 - Proceedings*, June, 1–4. <https://doi.org/10.1109/MECO.2019.8760294>
- Qi, X., & Mei, G. (2024). *Journal of King Saud University - Computer and*

Information Sciences Network Resilience : Definitions , approaches , and applications. 36(November 2023).

- Qin, Q., Li, J., Zhang, L., Yue, Y., & Liu, C. (2017). Combining Low-dimensional Wavelet Features and Support Vector Machine for arrhythmia beat classification. *Scientific Reports*, 7(1), 1–12. <https://doi.org/10.1038/s41598-017-06596-z>
- Rahmad, F., Suryanto, Y., & Ramli, K. (2020). Performance comparison of anti-spam technology using confusion matrix classification. *IOP Conference Series: Materials Science and Engineering*, 879(1). <https://doi.org/10.1088/1757-899X/879/1/012076>
- Rahman, S., Karmakar, C., Natgunanathan, I., Yearwood, J., & Palaniswami, M. (2022). Robustness of electrocardiogram signal quality indices. *Journal of the Royal Society Interface*, 19(189). <https://doi.org/10.1098/rsif.2022.0012>
- Rai, R. K., Singh, A., Srivastva, R., & Kumar, G. (2023). Fetal ECG arrhythmia detection based on DensNet Transfer Learning. *Frontiers in Biomedical Technologies*, 10(4), 417–426. <https://doi.org/10.18502/fbt.v10i4.13723>
- Rhif, M., Abbes, A. Ben, Farah, I. R., Martínez, B., & Sang, Y. (2019). Wavelet transform application for/in non-stationary time-series analysis: A review. *Applied Sciences (Switzerland)*, 9(7), 1–22. <https://doi.org/10.3390/app9071345>
- Ryu, S., Joe, I., & Kim, W. T. (2021). Intelligent forwarding strategy for congestion control using Q-learning and LSTM in named data networking. *Mobile Information Systems*. <https://doi.org/10.1155/2021/5595260>
- Sahoo, S., Dash, M., Behera, S., & Sabut, S. (2020). Machine Learning approach to detect cardiac arrhythmias in ECG signals: A Survey. *Irbm*, 41(4), 185–194. <https://doi.org/10.1016/j.irbm.2019.12.001>
- Sharma, A., Garg, N., Patidar, S., San Tan, R., & Acharya, U. R. (2020). Automated pre-screening of arrhythmia using hybrid combination of Fourier–Bessel expansion and LSTM. *Computers in Biology and Medicine*, 120(January). <https://doi.org/10.1016/j.combiomed.2020.103753>
- Sharma, L. D., Rahul, J., Aggarwal, A., & Bohat, V. K. (2023). An improved cardiac arrhythmia classification using stationary wavelet transform decomposed short duration QRS segment and Bi-LSTM network. *Multidimensional Systems and Signal Processing*, 34(2), 503–520. <https://doi.org/10.1007/s11045-023-00875-x>
- Sherly, S. I., & Mathivanan, G. (2021). ECG signal noises versus filters for signal quality improvement. *Proceedings of the 2021 1st International Conference on Advances in Electrical, Computing, Communications and Sustainable Technologies, ICAECT 2021*, 2–6. <https://doi.org/10.1109/ICAECT49130.2021.9392621>

- Sherstinsky, A. (2020). Fundamentals of recurrent neural network (rnn) and long short-term memory (lstm) network. *Physica D: Nonlinear Phenomena*, 404(March), 1–43. <https://doi.org/10.1016/j.physd.2019.132306>
- Sitompul, P., & Rosnelly, R. (2023). *Segmentation of Skin Cancer Images Using Fully Convolutional DenseNet - Tiramisu (One Hundred Layers)*. August, 130–138. <https://doi.org/10.7910/DVN/DBW86T>
- Skydt, M. R., Bang, M., & Shaker, H. R. (2021). A probabilistic sequence classification approach for early fault prediction in distribution grids using long short-term memory neural networks. *Measurement: Journal of the International Measurement Confederation*, 170, 108691. <https://doi.org/10.1016/j.measurement.2020.108691>
- Soydaner, D. (2020). A comparison of optimization algorithms for Deep Learning. *International Journal of Pattern Recognition and Artificial Intelligence*, 34(13). <https://doi.org/10.1142/S0218001420520138>
- Ullah, H., Bin Heyat, M. B., Akhtar, F., Sumbul, Muaad, A. Y., Islam, M. S., Abbas, Z., Pan, T., Gao, M., Lin, Y., & Lai, D. (2022). An end-to-end cardiac arrhythmia recognition Method with an Effective DenseNet Model on imbalanced datasets using ECG signal. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/9475162>
- Ullah, H., Bu, Y., Pan, T., Gao, M., Islam, S., Lin, Y., & Lai, D. (2021). Cardiac arrhythmia recognition using Transfer Learning with a Pre-trained DenseNet. *2021 IEEE 2nd International Conference on Pattern Recognition and Machine Learning, PRML 2021*, August 2022, 347–353. <https://doi.org/10.1109/PRML52754.2021.9520710>
- Wan, X., Mei, X., & Chen, Y. (2024). *Automated arrhythmia classification based on a pyramid dense connectivity layer and BiLSTM*. <https://doi.org/10.1177/09287329241290941>
- Wang, Q., Peng, R., & Wang, J. (2020). NEWLSTM : An optimized Long Short-Term Memory language model for sequence prediction. *IEEE Access*, 8, 65395–65401. <https://doi.org/10.1109/ACCESS.2020.2985418>
- Xiang, S., Qin, Y., Luo, J., Pu, H., & Tang, B. (2021). Multicellular LSTM-based Deep Learning model for aero-engine remaining useful life prediction. *Reliability Engineering and System Safety*, 216(June), 107927. <https://doi.org/10.1016/j.ress.2021.107927>
- Xie, S., Ren, G., & Zhu, J. (2020). Application of a new one-dimensional deep convolutional neural network for intelligent fault diagnosis of rolling bearings. *Science Progress*, 103(3), 1–18. <https://doi.org/10.1177/0036850420951394>
- Zhang, D., Zhou, H., Li, F., Zhang, L., & Wang, J. (2022). A reparameterization multifeature fusion cnn for arrhythmia heartbeats classification.

Computational and Mathematical Methods in Medicine, 2022.
<https://doi.org/10.1155/2022/7401175>

Zhang, H., Zhang, H., He, R., He, R., Dai, H., Dai, H., Xu, M., & Wang, Z. (2020). SS-SWT and SI-CNN: An atrial fibrillation detection framework for time-frequency ECG signal. *Journal of Healthcare Engineering*, 2020. <https://doi.org/10.1155/2020/7526825>

Zhou, J., Lu, Q., Xu, R., Gui, L., & Wang, H. (2020). EL_LSTM: Prediction of DNA-Binding Residue from protein sequence by Combining Long Short-Term Memory and Ensemble Learning. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 17(1), 124–135. <https://doi.org/10.1109/TCBB.2018.2858806>

Zhou, L., Zhao, C., Liu, N., Yao, X., & Cheng, Z. (2023). Improved LSTM-based deep learning model for COVID-19 prediction using optimized approach. *Engineering Applications of Artificial Intelligence*, 122(March), 106157. <https://doi.org/10.1016/j.engappai.2023.106157>

Zhou, Y., Wu, Z., Zhou, X., Ling, B. W. K., Mo, X., & Li, C. H. (2018). EMD Based Hierarchical Multiresolution Analysis via DCT with Applications to ECG Denoising and QRS Point Enhancement. *International Conference on Digital Signal Processing, DSP, 2018-Novem.* <https://doi.org/10.1109/ICDSP.2018.8631543>

Zhu, Q., He, Z., Zhang, T., & Cui, W. (2020). Improving classification performance of softmax loss function based on scalable batch-normalization. *Applied Sciences (Switzerland)*, 10(8), 1–8. <https://doi.org/10.3390/APP10082950>