

**KLASIFIKASI KONDISI PASIEN BERDASARKAN TANDA VITAL
MENGUNAKAN *BIDIRECTIONAL LONG
SHORT-TERM MEMORY***

SKRIPSI

Oleh:
NIZAM HUKMUL KAUTSAR
NIM. 220605110096



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

**KLASIFIKASI KONDISI PASIEN BERDASARKAN TANDA VITAL
MENGUNAKAN *BIDIRECTIONAL LONG
SHORT-TERM MEMORY***

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :
NIZAM HUKMUL KAUTSAR
NIM. 220605110096

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI UNIVERSITAS ISLAM
NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PERSETUJUAN


KLASIFIKASI KONDISI PASIEN BERDASARKAN TANDA VITAL MENGUNAKAN *BIDIRECTIONAL LONG SHORT-TERM MEMORY*

SKRIPSI

Oleh :
NIZAM HUKMUL KAUTSAR
NIM. 220605110096

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 22 Juni 2026

Pembimbing I,



Dr. Irwan Budi Santoso, M. Kom
NIP. 19770103 201101 1 004

Pembimbing II,


**Dr. Ir. Yunifa Miftachul Arif, S.ST., M.T.,
SMIEEE**
NIP. 19830616 201101 1 004

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Sanjaya M. Kom
NIP. 19891010 201903 1 012

HALAMAN PENGESAHAN

KLASIFIKASI KONDISI PASIEN BERDASARKAN TANDA VITAL MENGUNAKAN *BIDIRECTIONAL LONG SHORT-TERM MEMORY*

SKRIPSI

Oleh :

NIZAM HUKMUL KAUTSAR
NIM. 220605110096

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 22 Juni 2026

Susunan Dewan Penguji

Ketua Penguji : Prof. Dr. Suhartono, S.Si., M.Kom
NIP. 19680519 200312 1 001

Anggota Penguji I : Dr. Ririen Kusumawati, S.Si., M.Kom
NIP. 19720309 200501 2 002

Anggota Penguji II : Dr. Irwan Budi Santoso, M. Kom
NIP. 19770103 201101 1 004

Anggota Penguji III : Dr. Ir. Yunifa Miftachul Arif, S.ST.,
M.T., SMIEEE
NIP. 19830616 201101 1 004



Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Suhartono, M. Kom
NIP. 19680519 200312 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Nizam Hukmul Kautsar
NIM : 220605110096
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Klasifikasi Kondisi Pasien Berdasarkan Tanda Vital Menggunakan Bidirectional Long Short-Term Memory

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 22 Juni 2026
Yang membuat pernyataan,



Nizam Hukmul Kautsar
NIM 220605110096

MOTTO

“If I’m gonna tell a real story, I’m gonna start with my name.”

HALAMAN PERSEMBAHAN

Alhamdulillah *rabbil ‘alamin* puji syukur kepada Allah *Subhānahu wa Ta ‘ālā* karena berkat rahmat dan petunjuk-Nya penulis dapat menyelesaikan skripsi ini. Shalawat serta salam selalu tercurahkan kepada Rasulullah *Ṣallallāhu ‘Alaihi Wasallam* yang telah membawa kita dari zaman jahiliyah menuju *addinul Islam*. Skripsi ini penulis persembahkan kepada seluruh pihak yang telah berperan dan berjasa dalam perjalanan penelitian ini.

Pertama, penulis persembahkan skripsi ini kepada kedua orang tua tercinta. Terima kasih atas doa yang tidak pernah putus, dukungan yang selalu menguatkan, serta keyakinan dan kepercayaan yang diberikan kepada penulis dalam setiap langkah untuk menggapai cita-cita. Penulis juga mempersembahkan kepada kakak-kakak tercinta yang senantiasa memberikan motivasi, semangat, dan dukungan selama proses penyusunan skripsi ini.

Terakhir, penulis juga mempersembahkan kepada sahabat-sahabat seperjuangan skripsi dan teman-teman angkatan 2022 yang telah memberikan dukungan, semangat, motivasi, serta menemani dalam setiap proses, baik dalam suka maupun duka, hingga skripsi ini dapat terselesaikan.

Semoga segala kebaikan dan bantuan yang telah diberikan mendapatkan balasan terbaik dari Allah *Subhānahu wa Ta ‘ālā*. *Aamiin*.

KATA PENGANTAR

Segala puji hanya milik Allah *Subhānahu wa Ta‘ālā* atas segala nikmat dan kasih sayang-Nya yang telah memudahkan penulis untuk menyelesaikan skripsi yang berjudul “KLASIFIKASI KONDISI PASIEN BERDASARKAN TANDA VITAL MENGGUNAKAN BIDIRECTIONAL LONG SHORT-TERM MEMORY”. Semoga shalawat dan salam senantiasa terlimpah kepada Nabi Muhammad *Ṣallallāhu ‘Alaihi Wasallam*. Dan semoga kita semua mendapat syafaatnya di hari kiamat nanti, *Aamiin*. Penulis mengucapkan rasa syukur dan terima kasih yang tak terhingga kepada semua pihak-pihak yang selalu memberikan bantuan dan motivasi kepada penulis untuk dapat menyelesaikan skripsi ini. Ucapan ini penulis sampaikan kepada:

1. Prof. Dr. Hj. Ilfi Nurdiana, M.Si., CAHRM., CRMP, selaku Rektor Universitas Islam Negeri Malang, yang telah memberikan kesempatan dan fasilitas untuk menempuh pendidikan di universitas ini.
2. Dr. Agus Mulyono, M.Kes, selaku Dekan Fakultas Saintek Universitas Islam Negeri Malang, atas segala dukungan dan arahan yang diberikan selama proses studi.
3. Dr. Irwan Budi Santoso, M. Kom, selaku dosen pembimbing I dan Dr. Ir. Yunifa Miftachul Arif, S.ST., M.T., SMIEEE, selaku dosen pembimbing II yang telah memberikan bantuan dan arahan kepada penulis, sehingga bisa menuntaskan skripsi ini.

4. Prof. Dr. Suhartono, S.Si., M.Kom, selaku ketua penguji dan Dr. Ririen Kusumawati, M.kom, selaku dosen penguji II yang telah menguji serta memberikan masukan sehingga penulis dapat menuntaskan skripsi dengan baik.
5. Kedua orang tua serta saudara tercinta yang selalu menjadi sumber kekuatan, memberikan dukungan serta doa yang tulus tanpa henti, demi kelancaran dan keberhasilan penulis dalam menuntaskan skripsi ini.
6. Segenap Dosen, Admin, Laboran dan Mahasiswa Program Studi Teknik Informatika yang telah memberikan banyak dukungan dan bimbingan selama pengerjaan skripsi ini.
7. Diri sendiri atas setiap langkah kecil yang dijalani dengan usaha, kesabaran, dan doa hingga di titik ini. Penulis menyadari bahwa penyusunan skripsi ini masih terdapat kekurangan.
8. Grup “Pusat IMS” yang beranggotakan Ade, Alpin, Andra, Annas, Farhan, Fiqi, Hanif, Ilham, Amir, Johar, Yogi, Ical yang telah menemani penulis pada waktu mahasiswa baru serta memberikan pengalaman yang bermakna dan tidak pernah terlupakan.
9. Grup “STARBOY” dan “IPA 5” yang beranggotakan Algi, Farhan, Hafy, Novan, Avita, Ryan, Dewi, Dika, Sheva, Shoffy, Gideon, Varendra, Risma, yang ikut serta dalam memberikan semangat dan doa dikala suka maupun duka.

10. Teman-teman Mahad Ibn Rusyd khususnya kamar 18 beranggotakan Yogi, Fiqi, Andra, Johar, Anas, yang kebersamaan penulis pada waktu mahasiswa baru.
11. Grup “Sugi Kalcer” yang beranggotakan Ade, Yogi, Amir, Ilham, Ali, Rega, Faraz, Fuad, Fadil, Iqbal, Hakim, Alpin, Rahman, Thoriq, Kamal, Daffa, Hanif, Haikal, Aqip yang senantiasa hadir menemani, memberi semangat, dan berjuang bersama penulis selama masa pengerjaan skripsi ini.
12. Grup “BOS TAMBANG” yang beranggotakan Najib, Rega, Akbar, Zulham yang menemani penulis dalam mengerjakan skripsi setiap waktu.
13. Saudara Teknik Informatika khususnya INFINITY ‘22 yang telah menjadi bagian dari perjalanan akademik serta senantiasa saling mendukung dan berbagi informasi informasi.
14. Pemilik dan staf “Warung Kopi Ijo Ireng 99”, atas keramahan serta penyediaan tempat yang nyaman bagi penulis untuk fokus dan produktif dalam menyusun penelitian ini hingga selesai.
15. HIMATIF ENCODER khususnya Divisi Media Informasi ‘22 ‘21 dan Komunitas Otomasi dan Robotika Maliki ‘22 ‘23 atas pengalaman serta kesempatan untuk perkembangan diri penulis.
16. Teman-teman KKM “Sahwahita Abhipraya” yang telah menjadi teman dekat dan seperjuangan selama kegiatan kkm berlangsung.

17. Apresiasi penulis sampaikan kepada “Pamungkas” atas melodi dan lirik-liriknya yang telah memberi warna serta ruang kedamaian bagi penulis di tengah padatnya aktivitas penyusunan skripsi ini.
18. Kota Malang, yang senantiasa menyediakan suasana dingin dan sejuk, serta menghadirkan kedamaian di tengah keramaiannya, sehingga memberikan ketenangan tersendiri bagi penulis di setiap sudut kota.
19. Seluruh pihak yang telah banyak membantu dalam penyusunan skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan, sehingga kritik dan saran yang membangun sangat diharapkan untuk perbaikan di masa depan. Akhir kata, semoga skripsi ini bermanfaat bagi pengembangan ilmu pengetahuan dan bagi pembaca sekalian.

Malang, Juni 2026

Penulis

DAFTAR ISI

HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	xii
DAFTAR GAMBAR	xiv
DAFTAR TABEL	xv
ABSTRAK	xvi
ABSTRACT	xvii
البحث مستخلص	xviii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	4
BAB II STUDI PUSTAKA	6
2.1 Klasifikasi Resiko Mortalitas Pasien	6
2.2 Tanda Vital Dalam Medis	15
2.3 Data <i>Time Series</i> Dalam Bidang Kesehatan	16
2.4 BiLSTM	17
BAB III METODELOGI PENELITIAN	19
3.1 Prosedur Penelitian	19
3.2 Pengumpulan Data	20
3.3 Input Data	21
3.4 Desain Sistem	24
3.5 Data <i>Preprocessing</i>	27
3.5.1 <i>Scaling</i>	28
3.5.2 Transformasi Dan Perhitungan Atribut	30

3.5.3 Penanganan Batas Sekuens	33
3.5.4 Hasil <i>Preprocessing</i>	34
3.6 Bi-LSTM	35
3.6.1 <i>Split Data</i>	38
3.6.2 Evaluasi	40
3.6.3 Skenario Pengujian	42
BAB IV HASIL DAN PEMBAHASAN	44
4.1 Hasil Uji Coba	44
4.1.1 Pengujian Model A	44
4.1.2 Pengujian Model B	50
4.1.3 Pengujian Model C	57
4.2 Pembahasan	63
4.2.1 Perbandingan Model BiLSTM Setiap Skenario	63
4.2.2 Perbandingan Hasil dengan Penelitian Sejenis	69
4.3 Integrasi Sains dan Islam	71
BAB V KESIMPULAN DAN SARAN	73
5.1 Kesimpulan	73
5.2 Saran	74
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1 Struktur Jaringan BiLSTM.....	18
Gambar 3.1 Diagram Prosedur Penelitian.....	20
Gambar 3.2 <i>Flowchart</i> Desain Sistem BiLSTM.....	25
Gambar 3.3 Diagram Tahapan Data Preprocessing	28
Gambar 3.4 Arsitektur <i>Bidirectional Long Short-Term Memory</i> (BiLSTM).	36
Gambar 4.1 Visualisasi <i>Confusion matrix</i> Model A.....	46
Gambar 4.2 <i>Training Accuracy</i> Model BiLSTM Skenario A	47
Gambar 4.3 <i>Training Loss</i> Model BiLSTM Skenario A	48
Gambar 4.4 <i>Validation Accuracy</i> Model BiLSTM Skenario A.....	49
Gambar 4.5 <i>Validation Loss</i> Model BiLSTM Skenario A	49
Gambar 4.6 Kurva <i>Receiver Operating Characteristic</i> Pengujian A.....	50
Gambar 4.7 <i>Confusion matrix</i> Model B.....	52
Gambar 4.8 <i>Training Accuracy</i> Model BiLSTM Skenario B	53
Gambar 4.9 <i>Training Loss</i> Model BiLSTM Skenario B.....	54
Gambar 4.10 <i>Validation Accuracy</i> Model BiLSTM Skenario B.....	55
Gambar 4.11 <i>Validation Loss</i> Model BiLSTM Skenario B	55
Gambar 4.12 Kurva <i>Receiver Operating Characteristic</i> Pengujian B.....	56
Gambar 4.13 Visualisasi <i>Confusion matrix</i> Model C.....	58
Gambar 4.14 <i>Training Accuracy</i> Model BiLSTM Skenario C	60
Gambar 4.15 <i>Training Loss</i> Model BiLSTM Skenario C.....	60
Gambar 4.16 <i>Validation Accuracy</i> Model BiLSTM Skenario C.....	61
Gambar 4.17 <i>Validation Loss</i> Model BiLSTM Skenario C	62
Gambar 4.18 Kurva <i>Receiver Operating Characteristic</i> Pengujian C.....	63
Gambar 4.19 Visualisasi Perbandingan Model BiLSTM.....	64
Gambar 4.20 Grafik Perbandingan <i>Training Accuracy</i> BiLSTM	65
Gambar 4.21 Grafik Perbandingan <i>Validation Accuracy</i>	66
Gambar 4.22 Grafik Perbandingan <i>Training Loss</i>	67
Gambar 4.23 Grafik Perbandingan <i>Validation Loss</i>	68

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait.....	14
Tabel 3.1 Deskripsi Data	21
Tabel 3.2 Sampel Data Tanda Vital Pasien.....	23
Tabel 3.3 Rentang Normal Tanda Vital Orang Dewasa.	23
Tabel 3.4 Simbol dalam Rumus Perhitungan	24
Tabel 3.5 Data Vital Sebelum di <i>Scaling</i>	30
Tabel 3.6 Data Vital Setelah di <i>Scaling</i>	30
Tabel 3.7 Pembagian Dataset untuk Pelatihan dan Pengujian	40
Tabel 3.8 <i>Confusion matrix</i>	41
Tabel 3.9 Konfigurasi <i>Hyperparameter</i> Model BiLSTM	42
Tabel 4.1 Hasil Pengujian Model A	45
Tabel 4.2 Hasil <i>Confusion matrix</i> Mode A.....	46
Tabel 4.3 Hasil Perhitungan Matriks Evaluasi Model A.....	47
Tabel 4.4 Hasil Pengujian Model B	51
Tabel 4.5 Hasil <i>Confusion matrix</i> Model B	52
Tabel 4.6 Hasil Perhitungan Matriks Model B.....	53
Tabel 4.7 Hasil Pengujian Model C	57
Tabel 4.8 Hasil <i>Confusion matrix</i> Model C	59
Tabel 4.9 Hasil Perhitungan Matriks Model C.....	59

ABSTRAK

Kautsar, Nizam Hukmul. 2026. **Klasifikasi Kondisi Pasien Berdasarkan Tanda Vital Menggunakan *Bidirectional Long Short-Term Memory***. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Irwan Budi Santoso, M. Kom (II) Dr. Ir. Yunifa Miftachul Arif, S.ST., M.T., SMIEEE

Kata Kunci: Klasifikasi Pasien, Tanda Vital, *Time Series*, BiLSTM

Klasifikasi perburukan kondisi pasien di ICU maupun UGD masih menjadi tantangan karena sistem monitoring yang ada saat ini cenderung bersifat reaktif dan berfokus pada peringatan ambang batas normal. Penelitian ini mengusulkan model klasifikasi kondisi pasien yang proaktif berbasis *Bidirectional Long Short-Term Memory* dengan menggunakan data *time-series* tanda vital multivariat, yang meliputi detak jantung, laju pernapasan, tekanan darah, saturasi oksigen, dan suhu tubuh, serta tambahan atribut turunannya. Data bersumber dari *Kaggle* dan diproses secara sistematis melalui *Min-Max Scaling*, perhitungan atribut temporal tambahan, dan penanganan batas sekuens pasien. Pengujian dilakukan pada tiga skenario pembagian data yang berbeda. Hasil evaluasi menunjukkan bahwa Skenario A (rasio 80:10:10) selama 50 epoch memberikan performa terbaik dan paling tangguh, dengan tingkat Akurasi mencapai 88,57%, Presisi 90,32%, Recall 86,42%, dan F1-Score 88,33%. Kesimpulannya, arsitektur BiLSTM terbukti andal dalam mendeteksi pola temporal perburukan pasien secara dini dan akurat dengan meminimalkan kesalahan deteksi, sehingga sangat layak untuk diimplementasikan guna mendukung pengambilan keputusan klinis pada sistem pemantauan vital secara *real-time*.

ABSTRACT

Kautsar, Nizam Hukmul. 2026. **Patient Condition Classification Based on Vital Signs Using Bidirectional Long Short-Term Memory** Thesis. Department of Informatics Engineering, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University Malang. Advisors: (I) Dr. Irwan Budi Santoso, M. Kom (II) Dr. Ir. Yunifa Miftachul Arif, S.ST., M.T., SMIEEE

Keywords: *Patient Classification, Vital Signs, Time Series, BiLSTM*

Classification of patient deterioration in the ICU or emergency department remains a challenge due to current monitoring systems that tend to be reactive and focus solely on normal threshold alerts. This study proposes a proactive patient condition classification model based on Bidirectional Long Short-Term Memory (BiLSTM) using multivariate time-series vital sign data, encompassing heart rate, respiratory rate, blood pressure, oxygen saturation, and body temperature, along with their derived attributes. Data was sourced from Kaggle and systematically processed through Min-Max Scaling, calculation of additional temporal features, and sequence boundary handling. The testing was conducted across three different data-splitting scenarios. Evaluation results demonstrated that Scenario A (80:10:10 ratio) trained over 50 epochs yielded the best and most robust performance, achieving an Accuracy of 88.57%, Precision of 90.32%, Recall of 86.42%, and F1-Score of 88.33%. In conclusion, the BiLSTM architecture proved reliable in accurately detecting early temporal patterns of patient deterioration while minimizing false detection rates (false positives), making it highly feasible for implementation to support clinical decision-making in real-time vital monitoring systems.

البحث مستخلص

كاوتسار، نيزام هوكمول. 2026. تصنيف حالة المرضى بناءً على العلامات الحيوية باستخدام شبكة الذاكرة طويلة وقصيرة المدى ثنائية الاتجاه (Bidirectional Long Short-Term Memory). أطروحة تخرج. قسم هندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية، مالانج. المشرفان: (I) د. إيروان بودي سانتوسو، ماجستير في علوم الحاسوب (II) د. إير. يونيفا مفتاح العارف، بكالوريوس في العلوم والتكنولوجيا، ماجستير في الهندسة، عضو في الجمعية الهندسية للمهندسين الكهربائيين والإلكترونيين SMIEEE

الكلمات المفتاحية: تصنيف المرضى، العلامات الحيوية، السلاسل الزمنية، BiLSTM

لا يزال تصنيف تدهور حالة المرضى في وحدة العناية المركزة (ICU) أو قسم الطوارئ (UGD) يمثل تحدياً لأن أنظمة المراقبة الحالية تميل إلى أن تكون تفاعلية وتركز على الإنذارات عند تجاوز الحدود الطبيعية. تقترح هذه الدراسة نموذجاً استباقياً لتصنيف حالة المريض يعتمد على شبكة الذاكرة الطويلة والقصيرة المدى ثنائية الاتجاه (Bidirectional Long Short-Term Memory) باستخدام بيانات السلاسل الزمنية المتعددة المتغيرات لعلامات الحياة الحيوية، والتي تشمل معدل ضربات القلب، ومعدل التنفس، وضغط الدم، وتشبع الأكسجين، ودرجة حرارة الجسم، بالإضافة إلى السمات المشتقة منها. تم الحصول على البيانات من منصة Kaggle ومعالجتها بشكل منهجي من خلال تحويل النطاق (Min-Max Scaling)، وحساب السمات الزمنية الإضافية، ومعالجة حدود تسلسل المرضى. وأجريت الاختبارات على ثلاثة سيناريوهات مختلفة لتقسيم البيانات. أظهرت نتائج التقييم أن السيناريو «أ» (بنسبة 80:10:10) على مدار 50 دورة (epoch) قدم الأداء الأفضل والأكثر موثوقية، حيث بلغت نسبة الدقة 88,57%، والدقة النوعية 90,32%، ومعدل الاسترجاع 86,42%، ومؤشر F1-Score 88,33%. وختاماً، أثبتت بنية BiLSTM موثوقيتها في الكشف المبكر والدقيق عن الأنماط الزمنية لتدهور حالة المرضى مع تقليل أخطاء الكشف إلى الحد الأدنى، مما يجعلها جذيرة بالتطبيق لدعم اتخاذ القرارات السريرية في أنظمة مراقبة العلامات الحيوية في الوقت الفعلي.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Rumah sakit merupakan pusat layanan kesehatan yang menangani pasien dengan berbagai tingkat kondisi, mulai dari stabil hingga kritis. Pasien dengan kondisi serius, yang sedang dirawat di Unit Gawat Darurat (UGD) maupun Intensive Care Unit (ICU), tanda vital menjadi indikator utama dalam menilai status fisiologis pasien (Schwier, 2023). Menurut laporan World Health Organization (WHO, 2020), infeksi berat masih menjadi salah satu penyebab utama kematian dengan estimasi 11 juta kematian per tahun di seluruh dunia, dan sebagian besar kasus tersebut berkaitan dengan keterlambatan deteksi serta intervensi penanganan (Cassini *et al.*, 2017). Tanda vital sendiri merupakan sekumpulan parameter dasar yang merefleksikan fungsi tubuh paling esensial, meliputi detak jantung, tekanan darah, laju pernapasan, suhu tubuh, serta saturasi oksigen (Salhi *et al.*, 2023). Karena sifatnya yang fundamental, perubahan kecil pada tanda vital sering kali menjadi petunjuk awal terjadinya gangguan serius (Sundrani *et al.*, 2023). Namun, sistem monitoring tanda vital yang ada saat ini masih bersifat reaktif, hanya menampilkan data secara *real-time* dan mengeluarkan alarm ketika parameter berada di luar batas normal (Areia *et al.*, 2021). Akibatnya, pola perburukan pasien kerap tidak terdeteksi sejak dini, sehingga risiko keterlambatan intervensi medis tetap tinggi (Peters *et al.*, 2023). Oleh karenanya, dibutuhkan sistem klasifikasi otomatis kondisi pasien berbasis tanda vital yang mampu memberikan peringatan

dini dengan performa tinggi, sehingga dapat membantu dokter maupun tenaga medis dalam mengambil keputusan cepat dan tepat (Muralitharan *et al.*, 2021).

Secara ideal, sistem tersebut harus memberikan peringatan dini yang akurat agar tenaga medis dapat melakukan intervensi tepat waktu. Prinsip ini sejalan dengan kaidah medis bahwa pencegahan lebih baik daripada pengobatan, serta ditegaskan dalam firman Allah SWT pada QS. Al-Māidah ayat 32:

مِنْ أَجْلِ ذَلِكَ كَتَبْنَا عَلَىٰ بَنِي إِسْرَءِيلَ أَنَّهُ مَنْ قَتَلَ نَفْسًا بِغَيْرِ نَفْسٍ أَوْ فَسَادٍ فِي الْأَرْضِ فَكَأَنَّمَا قَتَلَ النَّاسَ جَمِيعًا وَمَنْ أَحْيَاهَا فَكَأَنَّمَا أَحْيَا النَّاسَ جَمِيعًا وَلَقَدْ جَاءَتْهُمْ رُسُلُنَا بِالْبَيِّنَاتِ ثُمَّ إِنَّ كَثِيرًا مِنْهُمْ بَعْدَ ذَلِكَ فِي الْأَرْضِ لَمُسْرِفُونَ ﴿٣٢﴾

“Oleh karena itu, Kami menetapkan (suatu hukum) bagi Bani Israil bahwa siapa yang membunuh seseorang bukan karena (orang yang dibunuh itu) telah membunuh orang lain atau karena telah berbuat kerusakan di bumi, maka seakan-akan dia telah membunuh semua manusia. Sebaliknya, siapa yang memelihara kehidupan seorang manusia, dia seakan-akan telah memelihara kehidupan semua manusia. Sungguh, rasul-rasul Kami benar-benar telah datang kepada mereka dengan (membawa) keterangan-keterangan yang jelas. Kemudian, sesungguhnya banyak di antara mereka setelah itu melampaui batas di bumi.” (QS. Al-Maidah: 32).

Ayat ini menjadi landasan moral dan religius bahwa menjaga keselamatan pasien adalah amanah yang sangat penting, termasuk melalui pemanfaatan ilmu pengetahuan dan teknologi. Dalam Tafsir Al-Misbah Volume 3, M. Quraish Shihab menjelaskan bahwa frasa "menghidupkan" atau "memelihara kehidupan seorang manusia" (ahyāhā) tidak hanya terbatas pada konteks menghindarkan seseorang dari bahaya pembunuhan fisik secara langsung. Lebih luas lagi, ayat ini mencakup segala bentuk usaha, sarana, dan ikhtiar kemanusiaan yang bertujuan untuk mempertahankan eksistensi hidup, mencegah kebinasaan, serta memelihara kesehatan manusia dari ancaman penyakit atau kelalaian medis (Shihab, 2002).

Keterlambatan intervensi medis masih menjadi tantangan besar di ICU maupun UGD karena sistem monitoring yang ada cenderung bersifat reaktif, hanya memberikan peringatan setelah tanda vital melewati ambang batas normal (Diao *et al.*, 2022). Padahal, tanda vital memiliki pola temporal yang kompleks, fluktuatif, dan sulit diinterpretasikan secara manual (Baker *et al.*, 2020). Perubahan kecil pada pasien dengan kondisi kritis, seperti sepsis atau gagal napas akut, sering kali tampak ringan pada awalnya, tetapi jika dianalisis secara berurutan dapat menunjukkan pola perburukan progresif. Fakta ini menegaskan pentingnya sistem klasifikasi yang mampu memanfaatkan informasi historis untuk mendeteksi risiko perburukan lebih dini dan akurat.

Dalam konteks tersebut, algoritma *Bidirectional Long Short-Term Memory* menawarkan solusi potensial. Berbeda dengan model machine learning klasik maupun pendekatan *deep learning unidirectional* seperti LSTM dan GRU, BiLSTM mampu memproses data *time series* dari dua arah, yaitu maju (*forward*) dan mundur (*backward*), sehingga dapat menangkap pola temporal secara lebih lengkap (Said *et al.*, 2021). Keunggulan ini sangat relevan untuk mengklasifikasi kondisi pasien karena memperhitungkan tren historis sekaligus kecenderungan ke depan. Oleh karena itu, penelitian ini difokuskan pada pengembangan model klasifikasi berbasis BiLSTM untuk mendeteksi risiko perburukan pasien secara lebih dini dan akurat, dengan harapan dapat mendukung pengambilan keputusan klinis yang cepat, meningkatkan keselamatan pasien, sekaligus memberikan kontribusi akademis dalam pengembangan metode klasifikasi berbasis *deep learning* di bidang kesehatan.

1.2 Rumusan Masalah

Bagaimana performa klasifikasi arsitektur *Bidirectional Long Short-Term Memory* pada data tanda vital yang kompleks berdasarkan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*?

1.3 Batasan Masalah

Penelitian ini dibatasi agar fokus pada tujuan yang telah ditetapkan sebagai berikut:

1. Data diambil dari EHR data Disease Progression dari Kaggle dengan parameter tanda vital berupa detak jantung, tekanan darah, laju pernapasan, suhu tubuh, dan saturasi oksigen (SpO₂).
2. Menggunakan *Confusin Matrix* untuk mengetahui hasil evaluasi dari model BiLSTM.

1.4 Tujuan Penelitian

Mengevaluasi kinerja arsitektur *Bidirectional Long Short-Term Memory* dalam melakukan klasifikasi kondisi pasien menggunakan data tanda vital yang kompleks, yang diukur berdasarkan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini meliputi beberapa aspek yang penting, diantaranya sebagai berikut:

1. Manfaat bagi Rumah Sakit: Penelitian ini diharapkan dapat menjadi dasar pengembangan sistem klasifikasi kondisi pasien yang mampu memberikan peringatan dini terhadap potensi perburukan. Dengan adanya sistem ini, rumah sakit dapat meningkatkan efisiensi penanganan pasien, mengoptimalkan penggunaan sumber daya medis, serta menurunkan angka keterlambatan intervensi yang berpotensi menyebabkan komplikasi serius maupun kematian.
2. Manfaat bagi Dokter/Tenaga Kerja Rumah Sakit: Hasil penelitian ini dapat membantu dokter dan tenaga kesehatan dalam mengambil keputusan klinis secara lebih dini dan akurat melalui dukungan klasifikasi otomatis berbasis data tanda vital pasien. Sistem ini dapat menjadi alat bantu deteksi dini yang mempercepat respons penanganan, sehingga meningkatkan kualitas pelayanan dan keselamatan pasien.

BAB II

STUDI PUSTAKA

2.1 Klasifikasi Resiko Mortalitas Pasien

Penelitian oleh Baker (2020) mengusulkan pendekatan hibrida berbasis *deep learning* untuk memprediksi risiko mortalitas pasien di ICU dengan memanfaatkan data tanda vital yang dikumpulkan secara kontinu. Dataset penelitian berasal dari database ICU publik yang berisi parameter fisiologis utama, seperti detak jantung, tekanan darah, laju pernapasan, dan suhu tubuh, yang diproses dalam jendela waktu 24 jam pertama perawatan. Metode yang digunakan adalah kombinasi Convolutional Neural Network (CNN) untuk ekstraksi fitur spasial dan *Bidirectional Long Short-Term Memory* (BiLSTM) untuk menangkap pola temporal dari data *time series*. Hasil evaluasi menunjukkan bahwa model hibrida CNN-BiLSTM secara signifikan mengungguli metode tradisional dan model *deep learning unidirectional*, dengan nilai Area Under the Curve (AUC) mencapai sekitar 0,884 dalam prediksi mortalitas. Temuan ini menegaskan bahwa pemodelan berbasis BiLSTM dapat memberikan prediksi lebih akurat pada data medis sekuensial, sehingga memiliki potensi besar dalam mendukung sistem peringatan dini di ICU.

Penelitian oleh Deng *et al.*, (2022) menganalisis model *deep learning time-series* yang dapat dijelaskan untuk prediksi mortalitas di rumah sakit, panjang rawat inap yang berkepanjangan (prolonged LOS), dan readmisi 30 hari pada pasien ICU menggunakan Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU), dan

Long Short-Term Memory (LSTM) dengan mekanisme attention untuk meningkatkan interpretabilitas, di mana variabel dipilih berdasarkan sistem scoring APACHE II, SOFA, dan SAPS II termasuk data demografi, vital signs, laboratorium, obat-obatan, dan prosedur yang dikumpulkan dalam 24 jam pertama setelah masuk ICU atau 24 jam terakhir sebelum pulang. Penelitian tersebut menggunakan dataset dari Medical Information Mart for Intensive Care-IV (MIMIC-IV) yang mencakup 40.083 pasien untuk prediksi mortalitas dan prolonged LOS serta 36.180 pasien untuk readmisi, dengan data dibagi menjadi set pelatihan (80%) dan pengujian (20%) setelah *preprocessing* seperti imputasi LOCF, one-hot encoding, dan penanganan *missing values*. Hasil penelitian menunjukkan performa model dengan AUC rata-rata 0.870 ± 0.001 untuk mortalitas, 0.765 ± 0.003 untuk prolonged LOS, dan 0.635 ± 0.018 untuk readmisi, di mana variabel penting yang diidentifikasi melalui attention meliputi Glasgow Coma Scale (GCS), usia, blood urea nitrogen (BUN), dan norepinephrine untuk mortalitas; GCS, ventilasi invasif, dan BUN untuk prolonged LOS; serta BUN, GCS, dan etnisitas untuk readmisi.

Penelitian oleh Alghatani *et al.*, (2021) mengembangkan model machine learning untuk memprediksi tingkat mortalitas dan lama perawatan (Length of Stay/LOS) pasien di ICU menggunakan data tanda vital. Studi ini memanfaatkan dataset MIMIC-III (44.626 kunjungan pasien) yang diproses melalui ekstraksi data hari pertama, imputasi mean untuk menangani nilai kosong, serta pembagian data latih-uji dengan rasio 75:25 menggunakan metode 10-fold cross-validation. Untuk meningkatkan kemampuan model, peneliti menerapkan pendekatan quantiles—

yakni proses rekayasa fitur yang menambahkan 21 atribut baru seperti nilai rata-rata, standar deviasi, dan persentil—untuk dibandingkan dengan model baseline. Evaluasi melibatkan enam algoritma klasifikasi biner guna memprediksi target mortalitas dan LOS biner (dikategorikan menjadi dua kelas waktu perawatan berdasarkan nilai tengah populasi), serta dua algoritma regresi untuk memprediksi LOS secara kontinu. Hasil penelitian membuktikan bahwa pendekatan quantiles secara konsisten memberikan performa terbaik. Algoritma Random Forest meraih akurasi tertinggi pada prediksi mortalitas (88,61%) dan klasifikasi LOS biner (64,64%), diikuti oleh Extreme Gradient Boosting yang mencapai nilai AUROC tertinggi (0,79). Sementara itu, untuk prediksi LOS kontinu, algoritma Support Vector Regression mencatatkan tingkat kesalahan terendah dengan Mean Absolute Error sebesar 2,81 hari.

Penelitian oleh Mehrdad *et al.*, (2022) menganalisis model prognostik untuk prediksi deteriorasi pasien COVID-19 menggunakan time-series tiga vital signs (SpO2, *Heart Rate*, *Temperature*) dan fitur klinis saat ini (sex, age, vaccination status, vaccination date, obesity, hypertension, diabetes) dengan deep neural network yang menggabungkan *Long Short-Term Memory* (LSTM) dengan temporal dilation untuk memproses data sekuensial (SEQ) dan Multi-Layer Perceptron (MLP) untuk mengintegrasikan fitur non-sekuensial, memprediksi deteriorasi (mortalitas in-hospital, masuk ICU, intubasi) dalam 3-24 jam berdasarkan data 24 jam sebelumnya melalui prosedur *Training* tiga fase (SEQ-only, penambahan non-SEQ, fine-tuning) dengan cross-entropy loss dan three-fold cross-validation. Penelitian tersebut menggunakan dataset NYU Langone De-identified COVID-19

yang mencakup 37.006 pasien (6.104 deteriorasi, 30.902 tidak) dari Januari 2020 hingga September 2022, dengan *preprocessing* termasuk interpolasi linier untuk *missing values* pada vital signs yang direkam setiap 4-5 jam. Hasil penelitian menunjukkan AUROC 0.808-0.880 dan AUPRC hingga 0.559 untuk prediksi 3-24 jam, dengan eksperimen oklusi mengonfirmasi pentingnya variasi temporal vital signs, melebihi performa model terkait seperti AUROC 0.765 pada prediksi 24 jam.

Penelitian oleh Lim *et al.*, (2024) menganalisis model machine learning *real-time* (iMORS) untuk prediksi mortalitas jangka pendek (24 jam) pada pasien kritis dengan ensemble *deep learning* dan light gradient boosting machine (LGBM), menggunakan 9 vital signs, 16 hasil laboratorium, dan usia setelah *preprocessing* seragam termasuk penggabungan fitur, imputasi *missing values* dengan *carry-forward/backward* serta median, normalisasi, dan seleksi fitur via occlusion analysis untuk menghindari *overfitting*, di mana model dilatih dengan *Temperature Scaling* untuk kalibrasi dan dievaluasi menggunakan AUROC dibandingkan National Early Warning Score (NEWS). Penelitian tersebut menggunakan dataset internal dari Seoul National University Hospital (SNUH) dengan 307.907 admisi ICU dari 2007-2021 (*Training* 2007-2018, *tuning* 2019, *testing* 2020-2021) serta eksternal MIMIC-III (53.423 pasien 2001-2012), eICU-CRD (200.859 stays 2014-2015), dan AmsterdamUMCdb (23.106 stays 2003-2016) setelah eksklusi pasien <18 tahun, DNR, penolakan LST, atau stay >60 hari. Hasil penelitian menunjukkan AUROC internal 0.964 (95% CI 0.963–0.965) dan eksternal 0.890 untuk MIMIC-III, 0.886 untuk eICU-CRD, 0.870 untuk AmsterdamUMCdb, outperform NEWS

($p < 0.001$), dengan Shapley values mengidentifikasi fitur penting seperti Glasgow Coma Scale, *Respiratory rate*, dan SpO2.

Penelitian oleh Fan *et al.*, (2024) menganalisis model prediksi *time series* multi-scale (BiLSTM-MLAM) untuk data sensor berdasarkan *Bidirectional Long Short-Term Memory* (Bi-LSTM) dan mekanisme local attention, di mana Bi-LSTM menangkap informasi *forward* dan *backward* dari data sekuensial, modul multi-scale patch segmentation menghasilkan urutan panjang yang terdiri dari segmen-segmen sama panjang dengan variasi ukuran patch untuk menangkap pola pada skala waktu berbeda, diikuti local attention yang mengidentifikasi dan memberi bobot pada segmen penting serta *feature fusion* untuk integrasi, dengan *preprocessing* mencakup normalisasi data ke mean 0 dan standar deviasi 1 serta pembagian data menjadi set *Training* dan testing untuk memastikan distribusi representatif. Penelitian tersebut menggunakan tiga dataset publik: C-MAPSS untuk prediksi remaining useful life (RUL) mesin pesawat dengan pemrosesan RUL calculation dan alignment, LTE dari Kaggle untuk prediksi traffic jaringan 4G, serta load dataset dari cm.asu.edu untuk prediksi beban listrik. Hasil penelitian menunjukkan performa superior dibandingkan enam baseline (LSTM, Bi-LSTM, GRU, TCN, Transformer, PatchTST), dengan peningkatan RMSE 6.66% dan MAE 11.50% pada C-MAPSS (RMSE 0.0938, MAE 0.0723), RMSE 12.77% dan MAE 3.06% pada LTE, serta RMSE 17.96% dan MAE 30.39% pada load dataset, sementara eksperimen ablasi mengonfirmasi kontribusi positif setiap modul dan tuning parameter patch length membuktikan kombinasi multi-scale menghasilkan error prediksi lebih rendah.

Penelitian oleh Su *et al.*, (2022) menganalisis model machine learning berbasis time-series (TEWS) untuk deteksi deteriorasi pasien rawat inap di bangsal umum menggunakan vital signs (*Heart Rate*, *Systolic blood pressure*, *Respiratory rate*) dari 48 jam sebelum event, di mana data dibagi menjadi enam time windows (TW) dan diproses dengan *Long Short-Term Memory* (LSTM) setelah feature selection *Sequential Backward Selection* (SBS) yang mengurangi dari 18 ke 5 fitur optimal, *preprocessing* termasuk under-sampling untuk imbalance, normalisasi, dan pembagian train/test untuk mengatasi ketidakseimbangan data. Penelitian tersebut menggunakan dataset dari electronic medical records 16.865 admisi dewasa di En-Chu-Kong Hospital, Taiwan (2007-2018), dengan 118 kasus in-hospital cardiac arrest (IHCA) sebagai event deteriorasi. Hasil penelitian menunjukkan AUROC 0.866 untuk TEWS dengan 6 TW, outperform Modified Early Warning Score (MEWS) (AUROC 0.663) dan klasifikasi lain seperti support vector machine (0.825) serta random forest (0.821), dengan sensitivitas lebih tinggi pada spesifisitas sama dalam dua task: prediksi IHCA menggunakan data 48 jam sebelum serta deteksi deteriorasi 48 jam sebelum event.

Penelitian oleh Mehrdad *et al.*, (2022) menganalisis model prognostik *deep learning* untuk prediksi deteriorasi pasien COVID-19 menggunakan time-series tiga vital signs (*SpO2*, *Heart Rate*, *Temperature*) dan fitur klinis non-sekuensial (sex, age, vaccination status, vaccination date, obesity, hypertension, diabetes) dengan arsitektur yang menggabungkan *Long Short-Term Memory* (LSTM) dengan temporal dilation untuk memproses data sekuensial serta Multi-Layer Perceptron (MLP) untuk fitur statis, memprediksi deteriorasi (mortalitas in-hospital, masuk

ICU, intubasi) dalam 3-24 jam berdasarkan data 24 jam sebelumnya melalui *Training* tiga fase (SEQ-only dengan Adam optimizer dan learning rate 0.001, penambahan non-SEQ, fine-tuning) menggunakan cross-entropy loss serta three-fold cross-validation untuk menangani imbalance dengan distribusi positif-negatif sama per fold. Penelitian tersebut menggunakan dataset NYU Langone De-identified COVID-19 dengan 37.006 pasien (6.104 deteriorasi, 30.902 tidak) dari Januari 2020 hingga September 2022, setelah *preprocessing* termasuk Z-score normalization, cubic spline interpolation untuk *missing values*, dan resampling setiap 15 menit. Hasil penelitian menunjukkan AUROC 0.808-0.880, AUPRC 0.559-0.666, dan akurasi 0.864-0.879 untuk prediksi 3-24 jam, dengan eksperimen occlusion mengonfirmasi kontribusi signifikan variasi temporal vital signs (terutama *Heart Rate*) serta outperform model baseline seperti SVS-Net dan MLVS-Net, melebihi AUROC 0.765 dari penelitian terkait menggunakan CXR dan variabel klinis.

Penelitian oleh Amer *et al.*, (2021) menganalisis model prediksi vital signs menggunakan k nearest neighbour least-squares support-vector machine (kNN-LS-SVM) untuk pasien COVID-19 di ICU, dengan ekstraksi fitur statistik (minimum, maximum, mean, median, standard deviation, energy) dari window tiga observasi sebelumnya untuk memprediksi nilai mendatang hingga tiga jam ke depan, di mana lima model dikembangkan: dua pertama menggunakan enam vital signs (*Heart Rate*/HR, *Systolic/Diastolic*/mean arterial blood pressure, *Respiration Rate*/RR, oxygen saturation/SpO2) dengan split 80/20 dan leave-one-subject-out, dua berikutnya fokus pada tiga vital signs (HR, RR, SpO2) dengan pendekatan serupa,

serta model kelima serupa dengan ketiga tapi observasi setiap 5 menit setelah *preprocessing* seperti interpolasi untuk *missing values* dan normalisasi. Penelitian tersebut menggunakan dataset dari 185 pasien ICU di tiga rumah sakit (ZOL Belgia: 51 pasien, MUMC+ Belanda: 50, CHU Liège Belgia: 84) selama gelombang pertama dan kedua pandemi, dengan vital signs direkam hourly/bi-hourly (8945 datapoints) atau 5-min (hanya 10 pasien). Hasil penelitian menunjukkan performa prediksi dalam mean absolute percentage error (MAPE), di mana model ketiga (tiga vital signs, hourly) mencapai MAPE rata-rata 12% untuk HR, 5% untuk SpO2, dan 21.4% untuk RR, sementara model kelima (5-min) meningkat menjadi 8%, 4.8%, dan 17.8% masing-masing, dengan leave-one-subject-out mirip dan histogram error serta early warning score (EWS) error mengonfirmasi peningkatan akurasi saat observasi lebih sering, meski BP hanya signifikan untuk RR.

Penelitian oleh Cui *et al.*, (2024) menganalisis metode baru untuk pengukuran tekanan darah non-invasif secara kontinu dengan menggabungkan sinyal Photoplethysmography (PPG) multi-gelombang menggunakan model Attention-based Convolutional Neural Network dan *Bidirectional Long Short-Term Memory* (ACNN-BiLSTM). Dataset yang digunakan diperoleh dari 162 relawan, termasuk 66 pasien hipertensi, dengan sinyal PPG empat panjang gelombang (660 nm, 730 nm, 850 nm, dan 940 nm) yang dikumpulkan menggunakan perangkat khusus dengan laju sampling 200 Hz. Data kemudian diproses melalui Continuous Wavelet Transform (CWT) untuk menghasilkan citra 2D sebelum dimasukkan ke dalam model. Evaluasi dilakukan dengan metrik MAE, RMSE, serta standar AAMI dan British Hypertension Society (BHS). Hasil menunjukkan bahwa model ACNN-

BiLSTM dengan fusi multi-gelombang menghasilkan akurasi prediksi terbaik, dengan MAE $\pm$ RMSE sebesar 1.67 ± 5.28 mmHg untuk SBP dan 1.15 ± 2.53 mmHg untuk DBP, serta memenuhi kriteria AAMI dan mendapatkan nilai A pada standar BHS. Hal ini menegaskan bahwa pendekatan berbasis multi-wavelength PPG fusion lebih unggul dibanding metode single-wavelength dalam meningkatkan akurasi prediksi tekanan darah

Tabel 2.1 Penelitian Terkait

NO	Peneliti & Tahun	Dataset	Metode	Hasil Utama	Keterbatasan
1	(Baker <i>et al.</i> , 2020)	ICU (vital signs 24 jam)	CNN + BiLSTM	AUC $\approx$ 0.884 untuk prediksi mortalitas	Fokus 24 jam; generalisasi terbatas
2	(Deng <i>et al.</i> , 2022)	MIMIC	ML klasik (RF, dsb.)	Akurasi mortalitas $\approx$ 89%	Kurang menangkap pola temporal
3	(Alghatani <i>et al.</i> , 2021)	MIMIC-IV	RNN/GRU/LSTM + attention	Performa baik + interpretabilitas	Perlu validasi eksternal
4	(Mehrdad <i>et al.</i> , 2022)	NYU COVID-19 (37k pasien)	Seq. DL (SpO ₂ , HR, T)	AUROC 0.81–0.88 (3–24 jam)	Khusus populasi COVID-19
5	(Lim <i>et al.</i> , 2024)	Data klinis kritis	Ensemble ML (<i>real-time</i>)	Prediksi mortalitas short-term valid lintas lokasi	Generalisasi etnisitas terbatas
6	(Fan <i>et al.</i> , 2024)	Data sensor umum	BiLSTM + attention	Prediksi <i>time series</i> lebih akurat dari baseline	Bukan dataset medis langsung
7	(Su <i>et al.</i> , 2022)	16.865 pasien rawat inap (Taiwan)	TEWS (LSTM)	AUROC > 0.8, lebih baik dari MEWS	Satu rumah sakit, vital sign terbatas
8	(Mehrdad <i>et al.</i> , 2023)	37.006 pasien COVID-19 (NYU)	TD-LSTM vs TCN	TCN unggul (AUROC 0.88–0.93) prediksi 3–24 jam	Hanya COVID-19, 3 vital sign

NO	Peneliti & Tahun	Dataset	Metode	Hasil Utama	Keterbatasan
9	(Amer <i>et al.</i> , 2021)	ICU COVID-19 (Mesir)	ML (SVR, ANN, RF)	ANN terbaik prediksi tanda vital	Dataset kecil, hanya COVID-19
10	(Cui <i>et al.</i> , 2024)	Data sinyal fisiologis (PPG)	ACNN + BiLSTM	Akurat prediksi sinyal kontinu	Bukan data klinis langsung

2.2 Tanda Vital Dalam Medis

Tanda vital merupakan parameter fisiologis utama yang mencerminkan kondisi kardiopulmoner dan homeostasis tubuh. Parameter ini umumnya meliputi detak jantung (*Heart Rate*/HR), tekanan darah (*Blood Pressure*/BP), laju napas (*Respiratory rate*/RR), suhu tubuh (*Temperature*/T), dan saturasi oksigen (SpO₂). Dalam praktik klinis, tanda vital berfungsi sebagai indikator awal perubahan status kesehatan pasien serta digunakan untuk triase, pemantauan intensif, dan evaluasi respons terapi. Karena berhubungan langsung dengan fungsi vital tubuh, tanda vital menjadi komponen penting dalam sistem peringatan dini dan pengambilan keputusan medis.

Pengukuran tanda vital dapat dilakukan secara kontinu maupun intermiten. Monitoring kontinu banyak diterapkan di unit perawatan intensif (ICU) dan ruang operasi melalui perangkat seperti electrocardiography (ECG), pulse oximeter, atau arterial line, yang menghasilkan data *time series* dengan resolusi tinggi. Sebaliknya, pengukuran intermiten menggunakan alat seperti tensimeter non-invasif (cuff) atau termometer klinis lebih umum diterapkan pada ruang rawat inap maupun rawat jalan. Perbedaan metode ini menyebabkan variasi frekuensi data: sinyal kontinu

dapat mencapai ratusan hingga ribuan Hz, sedangkan pengukuran intermiten biasanya hanya tersedia tiap menit hingga jam (Liu *et al.*, 2019).

Meskipun kaya informasi, data tanda vital memiliki keterbatasan seperti noise akibat gerakan, artefak sensor, nilai yang hilang, serta variasi antar-individu. Selain itu, pola temporalnya bersifat non-linear dan fluktuatif, sehingga sulit diinterpretasikan secara manual. Kondisi ini mendorong penggunaan metode analisis berbasis data yang lebih canggih, khususnya pendekatan *time series* modeling yang mampu menangkap dinamika temporal dan menghasilkan prediksi kondisi pasien secara lebih akurat dan dini (Clifford *et al.*, 2012).

2.3 Data *Time Series* Dalam Bidang Kesehatan

Data *time series* merupakan kumpulan data yang dicatat secara berurutan berdasarkan waktu dengan interval tertentu (Aljandali & Tatahi, 2018). Dalam konteks medis, data *time series* banyak diperoleh dari sistem monitoring pasien, seperti elektrokardiografi (ECG), oksimetri, atau rekaman tekanan darah arteri (Xie *et al.*, 2022). Karakteristik utama data ini adalah adanya ketergantungan antarwaktu (temporal dependency), sehingga nilai pada satu titik waktu sangat dipengaruhi oleh kondisi sebelumnya. Hal ini membedakan data *time series* medis dari data konvensional yang bersifat statis atau tidak berurutan.

Data *time series* medis memiliki sejumlah karakteristik khusus, antara lain bersifat multivariat (melibatkan lebih dari satu parameter fisiologis), non-stasioner (statistik distribusi berubah seiring waktu), serta non-linear. Tantangan lain yang sering dijumpai adalah adanya *missing values* akibat keterbatasan sensor, noise dari


artefak pergerakan pasien, dan perbedaan interval pencatatan antar perangkat. Kompleksitas tersebut membuat analisis data medis berbasis *time series* lebih menantang dibandingkan dengan data numerik biasa.

Meskipun demikian, data *time series* telah banyak dimanfaatkan dalam berbagai aplikasi medis. Beberapa penelitian menggunakan analisis *time series* untuk memprediksi mortalitas pasien ICU, mendeteksi dini terjadinya sepsis, mengidentifikasi aritmia dari sinyal ECG, hingga memperkirakan kemungkinan gagal napas pada pasien kritis. Dengan kemampuan untuk menangkap dinamika fisiologis pasien secara *real-time*, analisis *time series* memberikan kontribusi penting bagi pengembangan sistem pendukung keputusan klinis yang lebih akurat dan proaktif.

2.4 BiLSTM

Bidirectional Long Short-Term Memory (BiLSTM) merupakan pengembangan dari arsitektur LSTM yang memungkinkan jaringan untuk memproses urutan data dalam dua arah, yaitu maju (*forward*) dan mundur (*backward*) secara bersamaan (Said *et al.*, 2021). Jika pada LSTM konvensional informasi hanya mengalir dari masa lalu ke masa depan, maka BiLSTM menambahkan jalur pemrosesan terbalik yang membaca data dari arah sebaliknya (Yang *et al.*, 2023). Pendekatan dua arah ini memungkinkan jaringan menangkap konteks temporal secara lebih menyeluruh, sehingga sangat bermanfaat pada data *time series* di mana informasi penting dapat muncul baik sebelum maupun sesudah titik waktu tertentu.

Secara arsitektur, BiLSTM terdiri dari dua *hidden layer* LSTM terpisah: satu memproses data dalam arah maju dan satu lagi dalam arah mundur (Tofttrup *et al.*, 2021). Output dari kedua layer tersebut kemudian digabungkan untuk menghasilkan representasi fitur yang lebih kaya dan informatif. Gambar 2.2 berikut menunjukkan struktur dasar jaringan BiLSTM, yang terdiri dari *input layer*, *forward layer*, *backward layer*, dan *output layer*.



Gambar 2.1 Struktur Jaringan BiLSTM (Fan *et al.*, 2024).

Arsitektur BiLSTM memproses setiap titik waktu x_t melalui aliran informasi dua arah, sehingga dipengaruhi oleh keadaan sebelum maupun sesudahnya. Mekanisme ini memberikan pemahaman hubungan jangka panjang yang lebih kompleks dibandingkan LSTM standar. Kemampuan tersebut sangat krusial dalam analisis tanda vital untuk menangkap dinamika fisiologis yang fluktuatif dan non-linear guna mendukung deteksi dini kondisi kritis pasien.

BAB III

METODELOGI PENELITIAN

3.1 Prosedur Penelitian


Prosedur penelitian ini disusun untuk memberikan gambaran menyeluruh mengenai tahapan yang dilakukan dalam proses pembangunan model klasifikasi kondisi pasien berdasarkan data tanda vital berbasis *time series* menggunakan *Bidirectional Long Short-Term Memory* (BiLSTM). Setiap tahap dalam prosedur ini dirancang secara sistematis agar penelitian dapat dilakukan secara terarah dan menghasilkan model yang akurat serta dapat diandalkan.

Secara umum, prosedur penelitian ini terdiri atas beberapa tahapan utama, yaitu pengumpulan data, desain sistem, *preprocessing* data, perancangan model BiLSTM, evaluasi model, dan skenario pengujian. Tahap pertama, pengumpulan data, dilakukan untuk memperoleh dataset tanda vital pasien yang mencakup parameter fisiologis seperti *Heart Rate*, *Respiratory rate*, blood pressure, oxygen saturation (SpO_2), dan *Temperature*. Tahap kedua, desain sistem, bertujuan untuk memodelkan alur proses dari data mentah hingga hasil klasifikasi.

Tahap ketiga, data *preprocessing*, dilakukan untuk memastikan kualitas data agar sesuai dengan kebutuhan algoritma BiLSTM melalui proses pembersihan, normalisasi, segmentasi, dan pembentukan sequence. Selanjutnya, pada tahap keempat dilakukan perancangan model BiLSTM, di mana model dibangun dan dilatih menggunakan data latih yang telah diproses. Tahap kelima adalah evaluasi model, yaitu menilai performa model menggunakan metrik evaluasi seperti akurasi,

presisi, dan *F1-score*. Tahap terakhir adalah skenario pengujian dan uji coba, yang melibatkan pengujian berbagai konfigurasi model untuk memperoleh hasil terbaik dan melakukan evaluasi menyeluruh terhadap performa sistem.

Seluruh tahapan tersebut dilakukan secara berurutan sebagaimana ditunjukkan pada Gambar 3.1 Dengan prosedur penelitian ini, diharapkan model yang dihasilkan mampu memberikan hasil klasifikasi kondisi pasien yang akurat dan konsisten terhadap data tanda vital berbasis *time series*.



Gambar 3.1 Diagram Prosedur Penelitian

3.2 Pengumpulan Data

Sumber data yang digunakan dalam penelitian ini berasal dari dataset publik yang tersedia pada platform Kaggle dengan judul *EHR data - Disease Progression*. Dataset ini memuat rekaman tanda-tanda vital pasien yang dikumpulkan dalam bentuk deret waktu (*time series*). Pemilihan dataset ini didasarkan pada kesesuaiannya dengan tujuan penelitian, yaitu untuk klasifikasi kondisi pasien berdasarkan dinamika perubahan tanda vital.

Format data disajikan dalam bentuk tabel *time series*, di mana setiap baris merepresentasikan pengukuran tanda vital pasien pada waktu tertentu. Atribut utama dalam dataset meliputi *heart_rate*, *respiratory_rate*, *oxygen_saturation*, *bp_Systolic*, *bp_Diastolic*, *Temperature*, dan *progressed_to_critical*. Penjelasan masing-masing fitur ditunjukkan pada Tabel 3.1.

Tabel 3.1 Deskripsi Data

Fitur	Penjelasan
Patient_id	Id pasien
Day	Waktu pengukuran data pasien berdasarkan hari ke 1-30.
heart_rate	Jumlah detak jantung per menit [bpm]
respiratory_rate	Jumlah napas per menit [bpm]
oxygen_saturation	Persentase oksigen dalam darah [persentase]
bp_Systolic	Tekanan darah saat jantung berkontraksi [mmHg]
bp_Diastolic	Tekanan darah saat jantung beristirahat [mmHg]
Temperature	Suhu tubuh [$^{\circ}\text{Celcius}$]
progressed_to_critical	Kondisi Pasien (0 dan 1)

Frekuensi pencatatan data pada setiap variabel bergantung pada sistem pemantauan yang digunakan, sehingga sebelum dilakukan pemodelan dilakukan proses penyesuaian interval waktu agar seluruh data memiliki keseragaman skala temporal. Dataset ini terdiri atas ribuan baris pengamatan dengan ratusan sampel pasien, sehingga dianggap memadai untuk digunakan dalam proses pelatihan dan pengujian model *deep learning*.

3.3 Input Data

Data yang digunakan dalam penelitian ini berupa rekaman tanda vital pasien yang diperoleh dalam format *time series*. Tanda vital merupakan indikator fisiologis utama yang mencerminkan kondisi kesehatan pasien dan sering digunakan dalam pemantauan medis. Variabel yang dipilih sebagai fitur input pada penelitian ini

meliputi *patient_id*, *day*, *heart_rate*, *respiratory_rate*, *oxygen_saturation*, *bp_Systolic*, *bp_Diastolic*, *Temperature*. Variabel-variabel tersebut dipilih karena memiliki peran penting dalam mendeteksi perubahan fisiologis pasien, di mana abnormalitas pada salah satu tanda vital dapat menjadi indikator awal terjadinya perburukan kondisi klinis (Arik Eisenkraft, Yasmin Maor, Keren Constantini, Nir Goldstein, 2020).

Secara rinci, *Heart Rate* (HR) menggambarkan jumlah detak jantung per menit dan merupakan indikator utama fungsi kardiovaskular. *Respiratory rate* (RR) menunjukkan jumlah pernapasan per menit yang mencerminkan fungsi respirasi. *Oxygen Saturation* atau saturasi oksigen dalam darah mengindikasikan efektivitas pertukaran oksigen pada tubuh. Tekanan darah sistolik dan diastolik digunakan untuk menilai fungsi sirkulasi serta resistensi vaskular, sedangkan suhu tubuh menjadi indikator penting dalam mendeteksi adanya infeksi, demam, atau hipotermia. Seluruh variabel ini direkam secara periodik dengan frekuensi tertentu sehingga membentuk rangkaian data *time series* yang konsisten.

Sebelum dilakukan tahap *preprocessing*, data masih berada dalam bentuk mentah berupa tabel *time series* dengan setiap baris mewakili satu titik waktu pencatatan tanda vital. Sebagai ilustrasi, Tabel 3.2 berikut memperlihatkan contoh potongan data mentah dari dataset yang digunakan.

Tabel 3.2 Sampel Data Tanda Vital Pasien

Patient_id	Day	HR	RR	SpO ₂	Systolic	Diastolic	Temp
1	1	63	18	96.68941322	126	84	36.51163284
1	2	60	12	95.70204561	124	86	36.86170711
1	3	63	15	98.50826478	131	78	37.05204858
1	4	99	16	95.01180149	118	72	36.6547475
1	5	69	16	98.62379174	138	76	36.97509754

Dalam penelitian ini, target klasifikasi yang ditetapkan adalah kondisi pasien, yang dikategorikan menjadi dua kelas, yaitu *High Risk* dan *Low Risk*. Pasien dikatakan resiko kecil apabila nilai tanda vital berada dalam rentang normal, sedangkan kondisi resiko besar ditetapkan apabila terdapat penyimpangan signifikan dari ambang batas normal tanda vital. Apabila dataset yang digunakan tidak menyediakan label kondisi secara eksplisit, maka pelabelan dapat dilakukan menggunakan aturan berbasis ambang batas (rule-based threshold) yang merujuk pada literatur medis.

Sebagai acuan, rentang normal tanda vital pada orang dewasa ditunjukkan pada Tabel 3.3 berikut:

Tabel 3.3 Rentang Normal Tanda Vital Orang Dewasa (P. Liu *et al.*, 2025) & (Safiahani *et al.*, 2025).

Variabel	Rentang Normal	Keterangan
<i>Hearth Rate</i>	51 – 100 bpm	Denyut jantung per menit
<i>Respiratory rate</i>	9 – 14 bpm	Frekuensi pernapasan
SpO ₂	96%	Saturasi Oksigen darah
<i>Systolic BP</i>	100 – 179 mmHg	Tekanan darah sistolik
<i>Diastolic BP</i>	60 – 80 mmHg	Tekanan darah <i>Diastolic</i>
<i>Temperature</i>	35.1 - 35.9 C	Suhu tubuh normal.

Selanjutnya, untuk mengakomodasi karakteristik data *time series*, setiap data input akan dibentuk dalam bentuk sequence menggunakan pendekatan sliding window. Dalam penelitian ini, satu sequence terdiri atas data rekaman tanda vital selama lima menit, yang kemudian digunakan untuk klasifikasi kondisi pasien pada menit berikutnya. Dengan pendekatan ini, model BiLSTM dapat mempelajari pola temporal dari setiap variabel tanda vital sekaligus mempertimbangkan hubungan antar waktu sehingga menghasilkan klasifikasi yang lebih akurat. Simbol rumus perhitungan disajikan dalam 3.4 berikut.


Tabel 3.4 Simbol dalam Rumus Perhitungan

Data Vital	Keterangan	Simbol
<i>day</i>	Waktu pengukuran data pasien berdasarkan hari ke 1-30.	x_1
<i>heart_rate</i>	Jumlah detak jantung per menit [bpm]	x_2
<i>respiratory_rate</i>	Jumlah napas per menit [bpm]	x_3
<i>oxygen_saturation</i>	Persentase oksigen dalam darah [persentase]	x_4
<i>bp_Systolic</i>	Tekanan darah saat jantung berkontraksi [mmHg]	x_5
<i>bp_Diastolic</i>	Tekanan darah saat jantung beristirahat [mmHg]	x_6
<i>temperature</i>	Suhu tubuh [$^{\circ}\text{Celcius}$]	x_7

3.4 Desain Sistem

Desain sistem penelitian ini disusun untuk menggambarkan alur proses pemodelan klasifikasi kondisi pasien berdasarkan data *time series* tanda vital menggunakan pendekatan *Bidirectional Long Short-Term Memory* (BiLSTM). Sistem ini dirancang untuk mengolah data tanda vital pasien secara bertahap hingga menghasilkan klasifikasi kondisi pasien. Secara umum, alur sistem terdiri atas lima tahapan utama, yaitu data input, *preprocessing*, pelatihan model BiLSTM, dan output hasil klasifikasi.

Setiap tahapan pada sistem ini dirancang untuk saling terintegrasi, di mana data mentah yang masuk akan diproses secara bertahap hingga menghasilkan klasifikasi yang informatif. Dengan pendekatan BiLSTM, sistem mampu menangkap pola temporal dari data tanda vital pasien secara dua arah, sehingga meningkatkan akurasi klasifikasi dibandingkan metode *time series* satu arah. Visualisasi keseluruhan alur sistem ini dapat dilihat secara terstruktur pada Gambar 3.2.



Gambar 3.2 Flowchart Desain Sistem BiLSTM

Tahap data input berfungsi untuk memasukkan data mentah berupa tanda vital pasien yang dikumpulkan dalam bentuk deret waktu (time series). Data ini mencakup atribut utama seperti *heart_rate*, *respiratory_rate*, *oxygen_saturation*, *bp_Systolic*, *bp_Diastolic*, dan *Temperature*, serta *day* sebagai penanda waktu pengukuran. Selain itu, sistem juga mengelola *R* sebagai atribut hasil perhitungan tekanan darah rata-rata yang diperoleh dari kombinasi nilai *Systolic* dan *Diastolic*, sehingga memperkaya informasi fisiologis pasien.

Tahap berikutnya adalah *preprocessing*, yang terdiri atas beberapa proses utama. Pertama, dilakukan *Scaling* untuk menormalkan nilai setiap atribut agar seluruh data memiliki rentang nilai yang seragam disimbolkan x'_i , sehingga model dapat memproses setiap variabel tanpa adanya dominasi skala tertentu. Kedua, dilakukan transformasi dan perhitungan atribut, yaitu pembentukan atribut turunan berdasarkan perubahan nilai antar waktu, seperti *heart_rate* (perubahan detak jantung), *respiratory_rate* (perubahan laju pernapasan), dan *oxygen_saturation* (perubahan saturasi oksigen) disimbolkan Z_j^i , serta perhitungan R yang digunakan sebagai representasi tekanan darah rata-rata pasien. Ketiga, dilakukannya proses Penanganan Batas Sekuens (*Sequence Boundary Handling*). Tahap ini bertujuan untuk menjaga validitas data temporal dengan mengeliminasi distorsi perhitungan yang terjadi pada titik pergantian antar pasien.

Hasil dari tahap preprocessing berupa data numerik yang telah dinormalisasi dan diperkaya dengan atribut hasil transformasi serta perhitungan fisiologis tambahan. Data ini kemudian menjadi input bagi model BiLSTM. Pada tahap ini, model BiLSTM dilatih untuk mempelajari pola temporal dari data tanda vital pasien secara dua arah baik maju (*forward*) maupun mundur (*backward*) guna mengenali pola perubahan fisiologis secara lebih mendalam dan akurat. Tahap terakhir adalah *output*, di mana sistem menghasilkan hasil klasifikasi kondisi pasien, misalnya klasifikasi stabil atau kritis, yang dapat dijadikan dasar dalam pengambilan keputusan klinis maupun penelitian lebih lanjut.

Dengan desain sistem ini, setiap tahapan saling terintegrasi dan memiliki peran yang berkesinambungan, sehingga mendukung tujuan utama penelitian

dalam membangun model klasifikasi kondisi pasien berbasis *time series* yang andal, akurat, dan informatif.

3.5 Data Preprocessing


Tahapan data *preprocessing* merupakan proses penting yang bertujuan untuk menyiapkan data agar siap digunakan dalam pemodelan. Proses ini memastikan data memiliki kualitas yang baik, bebas dari kesalahan, dan sesuai dengan format yang dibutuhkan oleh model BiLSTM. Langkah pertama dimulai dari data vital pasien, yaitu data mentah yang berisi berbagai parameter fisiologis seperti denyut jantung, frekuensi pernapasan, tekanan darah, saturasi oksigen, dan suhu tubuh.

Tahap berikutnya adalah *Scaling*, di mana seluruh atribut numerik diseragamkan menggunakan metode *Min-Max Scaling* agar setiap atribut berada dalam rentang nilai yang sama dan tidak mendominasi proses pelatihan model. Setelah itu dilakukan ekstraksi informasi waktu, yaitu proses pembentukan struktur *time series* dengan mempertimbangkan urutan dan interval waktu pengukuran tanda vital.

Kemudian dilakukan transformasi dan perhitungan atribut untuk membentuk fitur tambahan yang lebih informatif, misalnya perubahan nilai (delta) antar waktu atau rerata per periode tertentu.

Terakhir, dilakukan proses Penanganan Batas Sekuens (Sequence Boundary Handling). Tahap ini bertujuan untuk mengatasi anomali perhitungan yang terjadi pada titik pergantian antar pasien akibat penggunaan metode selisih waktu ($j -$

j_{-1}). Pada proses ini, nilai atribut turunan (Z dan T) pada baris data hari pertama setiap pasien dihapus untuk memutus korelasi data antar subjek yang berbeda, sehingga menjamin integritas pola temporal yang dipelajari model. Setelah atribut siap dan tervalidasi, data dibagi melalui tahap split data menjadi dua bagian, yaitu data latih dan uji untuk menghindari *overfitting* pada model. Seluruh alur tahapan tersebut divisualisasikan pada Gambar 3.3 Tahapan Data Preprocessing.



Gambar 3.3 Diagram Tahapan Data *Preprocessing*

3.5.1 *Scaling*

Proses *Scaling* merupakan tahap penting dalam pemrosesan data untuk memastikan setiap fitur memiliki skala nilai yang seragam sebelum digunakan dalam proses pelatihan model BiLSTM. Hal ini dilakukan karena variabel tanda vital seperti *heart_rate*, *respiratory_rate*, *oxygen_saturation*, *bp_Systolic*, *bp_Diastolic*, dan *Temperature*. Perbedaan skala tersebut dapat menyebabkan model lebih sensitif terhadap fitur dengan nilai besar, seperti tekanan darah, dan mengabaikan fitur dengan nilai lebih kecil, seperti suhu tubuh. Oleh karena itu,

normalisasi diperlukan agar seluruh fitur berkontribusi secara seimbang terhadap proses pembelajaran model.

Metode penskalaan yang digunakan dalam penelitian ini adalah *Min-Max Scaling*, yang mentransformasikan setiap nilai fitur ke dalam rentang [0, 1]. Pendekatan ini dipilih karena cocok digunakan untuk data kontinu pada domain tanda vital serta mampu mempertahankan distribusi asli data tanpa mengubah bentuk pola deret waktunya (Pranolo *et al.*, 2024). Rumus perhitungan *Min-Max Scaling* ditunjukkan sebagai 3.1.

$$x'_i = \frac{x_{ij} - m_i}{M_i - m_i} \quad (3.1)$$

Keterangan:

- x'_i = hasil normalisasi pada atribut ke i .
- i = indeks variabel (mulai indeks ke 2 sampai ke 6).
- x_{ij} = data hasil pemeriksaan pasien pada atribut ke i waktu j
- m_i = nilai data minimum pada atribut ke i
- M_i = nilai data maximum pada atribut ke i

Sebelum dilakukan *Scaling*, data tanda vital memiliki rentang nilai yang bervariasi misalnya heart_rate berkisar antara 50 hingga 130 bpm, respiratory_rate antara 12 hingga 30 kali per menit, oxygen_saturation antara 85% hingga 100%, bp_Systolic antara 90 hingga 180 mmHg, bp_Diastolic antara 60 hingga 100 mmHg, serta suhu tubuh antara 35°C hingga 40°C. Setelah dilakukan proses penskalaan, seluruh fitur tersebut berada pada rentang 0 hingga 1 tanpa mengubah pola fluktuasi data aslinya. Proses ini dilakukan menggunakan pustaka *scikit-learn*

dengan fungsi *MinMaxScaler*, di mana tahap *fit* dan *transform* dilakukan hanya pada data latih untuk menghindari *data leakage*, sedangkan data uji hanya melalui tahap *transform*. Dengan demikian, hasil normalisasi ini memastikan model BiLSTM dapat mengenali pola perubahan tanda vital secara proporsional dan mempercepat proses konvergensi selama pelatihan disajikan pada tabel 3.5 sebelum *Scaling* dan tabel 3.6 setelah *Scaling*.

Tabel 3.5 Data Vital Sebelum di *Scaling*

patient_id	day	HR	RR	SpO2	Systolic	Diastolic	Temp
1	1	60	12	95.70204561	124	86	36.86170711
1	2	63	18	96.68941322	126	84	36.51163284
1	3	63	15	98.50826478	131	78	37.05204858
1	4	99	16	95.01180149	118	72	36.6547475
1	5	69	16	98.62379174	138	76	36.97509754

Tabel 3.6 Data Vital Setelah di *Scaling*

patient_id	day	HR	RR	SpO2	Systolic	Diastolic	Temp
1	1	0.000000	0.000000	0.191098	0.30	1.000000	0.647787
1	2	0.076923	1.000000	0.464456	0.40	0.857143	0.000000
1	3	0.076923	0.500000	0.968016	0.65	0.428571	1.000000
1	4	1.000000	0.666667	0.000000	0.00	0.000000	0.264823
1	5	0.230769	0.666667	1.000000	1.00	0.285714	0.857608

3.5.2 Transformasi Dan Perhitungan Atribut

Transformasi dan perhitungan atribut merupakan tahap lanjutan dalam proses data *preprocessing* yang berfokus pada pengolahan serta pembentukan atribut hasil transformasi agar data menjadi lebih informatif dan mampu

memperkuat kemampuan model dalam mengenali pola (X. Liu *et al.*, 2021). Tahapan ini dilakukan setelah proses *Scaling* dan ekstraksi informasi waktu, dengan tujuan menambah konteks temporal dan fisiologis dari data tanda vital pasien.

Data awal terdiri atas atribut utama seperti *Heart Rate*, *Respiration Rate*, *SpO₂*, *Systolic*, *Diastolic*, dan *Temperature*, serta atribut *day* yang menunjukkan urutan waktu pengamatan dari hari ke-1 hingga ke-30. Langkah pertama dalam proses transformasi atribut adalah menghitung perubahan nilai antar waktu dari beberapa parameter utama, seperti HR (perubahan detak jantung), RR (perubahan laju napas), dan SpO₂ (perubahan saturasi oksigen). Data atribut tersebut disimbolkan sebagai Z_{ij} sebagai hasil transformasi dan perhitungan atribut, X'_{ij} sebagai hasil normalisasi pada indeks atribut ke 2 sampai ke 4 waktu ke j , $X'_{i(j-1)}$ sebagai hasil normalisasi indeks atribut ke 2 sampai ke 4 waktu ke j (sebelumnya). Nilai-nilai ini diperoleh dari selisih antara pengukuran pada waktu saat ini dengan waktu sebelumnya, sesuai dengan rumus berikut:

$$Z_{ij} = X'_{ij} - X'_{i(j-1)} \quad (3.2)$$

Keterangan:

- i = indeks atribut (yang digunakan dalam perhitungan ini 2 sampai ke 4).
- Z_{ij} = perubahan nilai tanda vital pada atribut ke i waktu ke j
- X'_{ij} = hasil normalisasi atribut ke i pada waktu ke- j
- $X'_{i(j-1)}$ = hasil normalisasi atribut ke i pada waktu ke- j (sebelumnya).

Dari hasil perhitungan tersebut diperoleh beberapa atribut hasil transformasi seperti X'_{ij} meliputi HR, RR, SpO₂. Selain itu, dilakukan pula perhitungan baru atribut fisiologis berupa *Mean Arterial Pressure* (MAP) atau tekanan darah rata-

rata, yang dihitung dari nilai tekanan sistolik dan diastolik menggunakan rumus fisiologis berikut:

$$R = \frac{X'_{5j} + 2(X'_{6j})}{3} \quad (3.3)$$

Keterangan:

R	= tekanan darah rata-rata dari data indeks atribut ke 5 dan 6
X'_{5j}	= tekanan darah saat jantung berkontraksi
X'_{6j}	= tekanan darah saat jantung beristirahat

Tahap selanjutnya adalah melakukan perhitungan atribut perubahan suhu tubuh antar waktu (T). Atribut ini menggambarkan dinamika suhu tubuh pasien dari satu waktu pengamatan ke waktu berikutnya untuk mengidentifikasi adanya peningkatan atau penurunan suhu yang signifikan, yang dapat menjadi indikator perubahan kondisi fisiologis pasien. Rumus perhitungannya adalah sebagai berikut:

$$T = X'_{7j} - X'_{7(j-1)} \quad (3.4)$$

Keterangan:

T	= perubahan suhu tubuh antar waktu,
X'_{7j}	= nilai indeks pada atribut ke 7 pada waktu ke-j.
$X'_{7(j-1)}$	= nilai indeks pada atribut ke 7 pada waktu ke-j (sebelumnya).

Dengan menambahkan fitur-fitur turunan tersebut, dataset menjadi lebih kaya informasi dan mampu menggambarkan dinamika fisiologis pasien secara temporal. Fitur baru ini berperan penting dalam membantu model BiLSTM mengenali tren dan pola perubahan tanda vital yang dapat mengindikasikan kondisi pasien.

Dengan menambahkan atribut hasil transformasi tersebut, dataset menjadi lebih informatif dan mampu merepresentasikan dinamika fisiologis pasien secara temporal. Hasil dari proses ini ditampilkan pada halaman lampiran, yang menunjukkan data sebelum transformasi dan perhitungan atribut, serta lembaran lampiran selanjutnya, yang menampilkan data setelah transformasi dan perhitungan atribut. Kedua tabel ini memperlihatkan perbedaan struktur data sebelum dan sesudah proses *preprocessing*, di mana atribut tambahan seperti Z_{ij} , R , dan T telah berhasil diintegrasikan untuk memperkaya konteks temporal pada model BiLSTM

3.5.3 Penanganan Batas Sekuens

Penanganan batas sekuens merupakan langkah krusial untuk menjaga integritas data temporal dalam dataset yang bersifat multi-pasien. Mengingat dataset terdiri dari ribuan baris observasi yang mencakup berbagai subjek berbeda yang diidentifikasi melalui *patient_id* serta urutan waktu pengamatan yang dicatat dalam atribut *day*, terdapat risiko terjadinya distorsi data pada titik transisi antar pasien. Tanpa penanganan khusus, perhitungan atribut transformasi seperti perubahan tanda vital (Z_{ij}) dan perubahan suhu (T) pada baris pertama seorang pasien akan secara keliru mengambil nilai dari baris terakhir pasien sebelumnya dalam tabel mentah. Hal ini dapat mengakibatkan model mempelajari pola hubungan semu yang tidak valid antar individu yang berbeda, yang berpotensi merusak akurasi klasifikasi.

Oleh karena itu, sistem melakukan validasi ketat pada setiap perpindahan *patient_id*. Untuk setiap baris data yang terdeteksi sebagai hari pertama atau data

awal seorang pasien, nilai atribut turunan yang mengandalkan selisih waktu ($j - (j - 1)$) akan dieliminasi atau diputus. Proses ini memastikan bahwa setiap sekuens yang dipelajari oleh model BiLSTM benar-benar hanya mencerminkan dinamika fisiologis internal dari satu pasien secara mandiri, tanpa terpengaruh oleh tren kesehatan pasien lain yang kebetulan berada pada urutan baris di atasnya dalam dataset. Dengan memutus korelasi antar subjek ini, integritas pola temporal tetap terjaga sehingga model mampu memberikan klasifikasi kondisi pasien yang lebih objektif dan andal.


3.5.4 Hasil *Preprocessing*

Hasil *preprocessing* menunjukkan transformasi data vital pasien dalam bentuk *time series* yang telah siap digunakan untuk pemodelan BiLSTM, sesuai dengan tahapan yang diterapkan pada proses *Data Preprocessing*. Proses ini dimulai dengan *Scaling* data, yang bertujuan untuk mengubah data ke rentang $[0, 1]$ untuk memastikan stabilitas pembelajaran model (Cao *et al.*, 2016). Terakhir, Transformasi dan perhitungan atribut menghasilkan atribut dinamika seperti perubahan antar time step Z_{2j} sebagai HR, Z_{3j} sebagai RR, Z_{4j} sebagai SpO₂, tekanan darah rata-rata R , dan perubahan suhu T , yang disajikan dalam lembar lampiran. Data dalam tabel ini mencerminkan hasil akhir *preprocessing*, di mana setiap baris mewakili satu time step yang telah dioptimalkan untuk analisis pola temporal dalam pemodelan BiLSTM.

3.6 Bi-LSTM

Model *Bidirectional Long Short-Term Memory* (BiLSTM) merupakan pengembangan dari jaringan LSTM yang dirancang untuk memproses data deret waktu (*time series*) secara dua arah, yaitu maju dan mundur (Abduljabbar *et al.*, 2021). Dengan dua arah pemrosesan ini, BiLSTM mampu menangkap hubungan temporal baik dari konteks masa lalu maupun masa depan secara bersamaan (Xiang *et al.*, 2020). Setiap unit BiLSTM memiliki komponen utama berupa input gate, forget gate, dan output gate yang berfungsi untuk mengatur aliran informasi agar jaringan dapat mengingat data penting dan melupakan data yang tidak relevan (Huan *et al.*, 2020). Karakteristik ini menjadikan BiLSTM unggul dalam mendeteksi pola kompleks pada data tanda vital pasien, seperti fluktuasi detak jantung, tekanan darah, dan suhu tubuh yang berubah secara dinamis dari waktu ke waktu.

Pada penelitian ini, arsitektur model BiLSTM dirancang untuk memproses data time series tanda vital yang telah melalui tahap preprocessing. Input model dinotasikan sebagai $Q = \{Z, R, T\}$ Dimana Z hasil transformasi dan perhitungan atribut indeks turunan HR, RR, SpO2, R merupakan data indeks atribut indeks ke 5 dan 6 rata rata, serta T merupakan data hasil perhitungan perubahan suhu tubuh antar waktu. Ketiga komponen tersebut digabungkan sebagai representasi kondisi fisiologis pasien pada setiap timestep untuk kemudian dimasukkan ke model BiLSTM dalam bentuk *multivariate feature vector*. Dengan pendekatan ini, model mampu melihat informasi statis, dinamis, serta perubahan fisiologis secara temporal secara bersamaan.



Gambar 3.4 Arsitektur *Bidirectional Long Short-Term Memory* (BiLSTM).

Model BiLSTM memproses vektor input Q secara dua arah, yaitu *forward* dan *backward*, sehingga mampu menangkap pola temporal baik dari masa lalu menuju masa depan maupun sebaliknya. Output dari BiLSTM pada timestep t kemudian dipetakan menjadi simbol KP yang merepresentasikan kondisi pasien pada waktu tersebut. Dengan demikian, BiLSTM tidak hanya memahami nilai absolut dari tanda vital, tetapi juga dinamika perubahan atribut fisiologis antar waktu yang berkontribusi terhadap penentuan kondisi pasien. Mekanisme ini diharapkan meningkatkan akurasi klasifikasi serta sensitivitas model terhadap perubahan fisiologis kecil yang memiliki relevansi klinis pada kondisi kritikal.

$$f_t^{forward} = \sigma(W_f^{forward} \cdot [h_{t-1}^{forward}, Q_t] + b_f^{forward}) \quad (3.5)$$

$$f_t^{backward} = \sigma(W_f^{backward} \cdot [h_{t-1}^{backward}, Q_t] + b_f^{backward}) \quad (3.6)$$

Setelah *Forget Gate Forward* dan *backward* selesai dihitung, Langkah selanjutnya adalah memperbarui cell state melalui input gate. Input gate bertugas

untuk menentukan informasi baru yang relevan dari input dan *hidden state* sebelumnya yang akan disimpan pada cell state. Berikut merupakan proses perhitungan antara *forward* dan *backward*.

$$i_t^{forward} = \sigma(W_i^{forward} \cdot [h_{t-1}^{forward}, Q_t] + b_i^{forward}) \quad (3.7)$$

$$i_t^{backward} = \sigma(W_t^{backward} \cdot [h_{t+1}^{backward}, Q_t] + b_t^{backward}) \quad (3.8)$$

Setelah melalui perhitungan *input gate*, proses selanjutnya adalah perhitungan *candidate cell state*. *Candidate cell state* adalah langkah penting dalam mekanisme BiLSTM, dimana nilai ini merepresentasikan informasi baru yang akan ditambahkan ke *cell state* berdasarkan input saat ini dan *hidden state* sebelumnya. Perhitungan dilakukan dengan menerapkan fungsi aktivasi *tanh*. Berikut merupakan proses perhitungannya antara langkah *forward* dan *backward*.

$$\bar{C}_t^{forward} = \tanh(W_c^{forward} \cdot [h_{t-1}^{forward}, Q_t] + b_c^{forward}) \quad (3.9)$$

$$\bar{C}_t^{backward} = \tanh(W_c^{backward} \cdot [h_{t+1}^{backward}, Q_t] + b_c^{backward}) \quad (3.10)$$

Langkah berikutnya dalam arsitektur BiLSTM adalah memperbarui *cell state* untuk setiap arah. Pada tahap ini, cell state diperbarui dengan cara menggabungkan informasi dari forget gate, *input gate*, dan *candidate cell state* yang telah dihitung sebelumnya. Perhitungan ini dilakukan secara rinci untuk arah *forward* dan *backward* agar BiLSTM dapat memahami pola data secara lebih

mendalam dari kedua arah sekuensial. Berikut merupakan perhitungannya untuk *forward* dan *backward*.

$$C_t^{forward} = f_t^{forward} \cdot C_{t-1}^{forward} + i_t^{forward} \cdot \bar{C}_t^{forward} \quad (3.11)$$

$$C_t^{backward} = f_t^{backward} \cdot C_{t+1}^{backward} + i_t^{backward} \cdot \bar{C}_t^{backward} \quad (3.12)$$

Langkah terakhir pada cara kerja BiLSTM adalah menentukan hasil output. Bagian ini menggunakan output gate yang akan menentukan bagian dari cell state mana yang akan menjadi output. Output ini nantinya akan dimasukkan dalam tanh layer dan diberi fungsi aktivasi tanh. Hasilnya akan dikalikan dengan output dari output gate. Berikut merupakan perhitungannya untuk *forward* dan *backward*.

$$O_t^{forward} = \sigma(W_o^{forward} [h_{t-1}^{forward}, Q_t] + b_o^{forward}) \quad (3.13)$$

$$O_t^{backward} = \sigma(W_o^{backward} [h_{t-1}^{backward}, Q_t] + b_o^{backward}) \quad (3.14)$$

$$h_t^{forward} = O_t^{forward} \cdot \tanh(C_t^{forward}) \quad (3.15)$$

$$h_t^{backward} = O_t^{backward} \cdot \tanh(C_t^{backward}) \quad (3.16)$$

3.6.1 Split Data

Tahap split data merupakan langkah awal dalam proses Model *Training* and *Testing* untuk mempersiapkan data guna mendukung pemodelan BiLSTM dalam mengklasifikasi kondisi pasien. Pada tahap ini, data dibagi menjadi set pelatihan (*Training set*), set validasi (*validation set*), dan set uji (*testing set*) dengan rasio yang bervariasi untuk mengoptimalkan performa model (Nguyen *et al.*, 2021). Rasio yang digunakan meliputi 80:10:10, di mana 80% data dialokasikan untuk pelatihan,

10% untuk validasi, dan 10% untuk pengujian, serta alternatif rasio seperti 70:15:15 dan 60:20:20 untuk mengevaluasi fleksibilitas model (Nguyen *et al.*, 2021). Pembagian ini dilakukan secara temporal untuk menjaga urutan data *time series*.

Untuk mencegah overfitting, penelitian ini mengalokasikan set validasi guna memantau perkembangan performa model secara kontinu selama proses pelatihan berlangsung. Pengalokasian tersebut mengikuti rekomendasi untuk mengambil 10-20% dari total data sebagai validation set (sekitar 116 hingga 233 pasien dari total 1.164 pasien unik) guna memantau gejala overfitting tanpa mengurangi proporsi data pelatihan secara signifikan. Selain itu, penggunaan dropout dengan probabilitas 0,2 hingga 0,5, khususnya sebesar 0,3 pada layer BiLSTM, diterapkan sebagai teknik regularisasi tambahan untuk mengurangi ketergantungan model pada fitur tertentu. Teknik cross-validation temporal yang kompleks seperti 5-fold dihindari karena pertimbangan efisiensi waktu komputasi pada dataset yang mencapai 34.920 baris data, sehingga pembagian data secara statis dipilih agar model tetap mampu melakukan generalisasi dengan baik pada data yang belum dilihat guna mendukung akurasi klasifikasi kondisi pasien. Berdasarkan perhitungan rasio ini, Tabel 3.7 menyajikan detail pembagian sampel untuk setiap skenario split data yang menjadi dasar pelaksanaan pelatihan dan pengujian model secara sistematis.

Tabel 3.7 Pembagian Dataset untuk Pelatihan dan Pengujian (Lateef & Adebola, 2026).

Model Rasio	Training Set	Validation Set (Sampel)	Testing Set (Sampel)
A (80:10:10)	20.940	6.990	6.990
B (70:15:15)	24.450	6.990	3.480
C (60:20:20)	27.930	3.480	3.510

3.6.2 Evaluasi

Hasil evaluasi merupakan tahap akhir proses Model Training and Testing untuk mengukur performa model BiLSTM dalam mengklasifikasikan data time series tanda vital pasien. Evaluasi ini membandingkan hasil klasifikasi model dengan label aktual pada testing set menggunakan beberapa metrik utama. Akurasi menggambarkan tingkat ketepatan keseluruhan model dari total klasifikasi yang benar. Precision menilai ketepatan model dalam mendeteksi kondisi positif tertentu dari seluruh prediksi positifnya, sedangkan Recall mengukur sensitivitas model dalam mengenali seluruh kasus positif yang sebenarnya. Perhitungan metrik tersebut didasarkan pada empat elemen: *True Positive* (TP) untuk prediksi abnormal yang benar, *True Negative* (TN) untuk prediksi normal yang benar, *False Positive* (FP) untuk kondisi normal yang keliru diprediksi abnormal, dan *False Negative* (FN) untuk kondisi abnormal yang luput diprediksi. Selanjutnya, F1-score digunakan sebagai rata-rata harmonik antara Precision dan Recall untuk memberikan keseimbangan performa pada data yang tidak seimbang. Terakhir, visualisasi seperti kurva loss, akurasi per epoch, dan Confusion Matrix turut diterapkan untuk memberikan gambaran mendalam mengenai stabilitas serta

keandalan model. (Hicks *et al.*, 2022). Tabel *Confusion matrix* disajikan pada 3.8 berikut.

Tabel 3.8 *Confusion matrix* (Hicks *et al.*, 2022).

<i>Actual</i>	<i>Predicted</i>		
		<i>Normal</i>	<i>Abnormal</i>
	<i>Normal</i>	<i>True Positive (TP)</i>	<i>False Negative (FN)</i>
	<i>Abnormal</i>	<i>False Positive (FP)</i>	<i>True Negative (TN)</i>

Keterangan:

TP = Model mengklasifikasi kondisi normal secara benar.

TN = Model mengklasifikasi kondisi abnormal secara benar.

FP = Model mengklasifikasi normal, padahal kondisi sebenarnya abnormal.

FN = Model mengklasifikasi abnormal, padahal kondisi sebenarnya normal.

Confusion matrix digunakan untuk mengevaluasi kinerja model BiLSTM dalam mengklasifikasikan kondisi pasien berdasarkan tanda vital. Matriks ini membandingkan hasil prediksi model dengan label aktual, di mana nilai TP dan TN merepresentasikan klasifikasi yang benar, sementara FP dan FN menunjukkan kesalahan prediksi. Data dari matriks ini menjadi dasar perhitungan metrik evaluasi berupa *Accuracy*, *Precision*, *Recall*, dan *F1-score* guna mengukur performa model secara menyeluruh melalui rumus berikut (Airalngga, 2025).

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (3.17)$$

$$Precision = \frac{TP}{(TP + FP)} \quad (3.18)$$

$$Recall = \frac{TP}{(TP + FN)} \quad (3.19)$$

$$F1-Score = \frac{2 * (Precision * Recall)}{(Precision + Recall)} \quad (3.20)$$

3.6.3 Skenario Pengujian

Penelitian ini menggunakan tiga skenario uji coba untuk menguji performa model BiLSTM dalam mengklasifikasi kondisi pasien berdasarkan data *time series* tanda vital. Skenario pertama menggunakan rasio pembagian data sebesar 80% data training, 10% data testing, 10% data validai. Skenario kedua menggunakan rasio 70% data pelatihan, 15% data validasi, dan 15% data testing. Skenario ketiga menggunakan rasio 60% data latih, 20% data uji, 20% data validasi. Secara keseluruhan 3 skenario pengujian diatas memakai data dengan total 34.920 sampel untuk menguji kemampuan generalisasi model terhadap variasi temporal yang lebih luas. Parameter model yang digunakan ditetapkan untuk mencapai keseimbangan antara akurasi dan efisiensi komputasi, dengan konfigurasi sebagai berikut:

Tabel 3.9 Konfigurasi *Hyperparameter* Model BiLSTM

No	<i>Hyperparameter</i>	Nilai	Keterangan
1	Jumlah Neuron	16, 32, 64	Unit pada lapisan tersembunyi BiLSTM
2	Learning Rate	0.0001, 0.001	Kecepatan pembaruan bobot
3	Epoch	30, 50	Jumlah iterasi pelatihan
4	Batch Size	32, 64	Jumlah sampel per batch
5	Optimizer	Adam	Algoritma optimasi
6	Fungsi aktivasi	Tanh, sigmoid	Aktivasi pada BiLSTM dan output
7	Loss Function	MSE	Mengukur selisih klasifikasi dan actual
8	Perangkat	GPU	Mempercepat pelatihan model

Konfigurasi ini dioptimalkan menggunakan untuk mempercepat proses pelatihan. Hasil uji coba ini menjadi dasar dalam menilai efektivitas model

BiLSTM untuk diterapkan pada sistem klasifikasi kondisi pasien secara *real-time* di lingkungan medis seperti ICU atau UGD.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Uji Coba

Hasil uji coba memaparkan analisis kinerja model BiLSTM berdasarkan tiga skenario pembagian data yang telah ditetapkan, yaitu Skenario A (80:10:10), Skenario B (70:15:15), dan Skenario C (60:20:20). Pengujian ini dilakukan untuk melihat konsistensi model dalam mengklasifikasi mengkondisi pasien apakah berada pada kondisi Stabil (Kelas 0) atau Tidak Stabil (Kelas 1) dengan menggunakan fitur input multivariat $Q = Z, R, T$. Evaluasi difokuskan pada kemampuan model dalam menjaga keseimbangan antara *Precision* dan *Recall*, mengingat pentingnya mendeteksi risiko perburukan pasien sedini mungkin.


4.1.1 Pengujian Model A

Skenario pengujian pertama ini menerapkan pembagian dataset dengan rasio 80:10:10, di mana 80% data dialokasikan untuk pelatihan (*training*), 10% untuk validasi (*validation*), dan 10% untuk pengujian (*testing*). Pada skenario ini, dilakukan serangkaian percobaan untuk mengevaluasi kinerja model BiLSTM dengan memvariasikan *Hyperparameter* utama, yaitu jumlah *neuron*, *learning rate*, *epoch*, dan *batch size*. Ringkasan hasil evaluasi performa model berdasarkan metrik *accuracy*, *precision*, *recall*, dan *f1-score* disajikan secara lengkap pada Tabel 4.2 berikut.

Tabel 4.1 Hasil Pengujian Model A

Model	Neuron	Learning Rate	Epoch	Batch Size	Accuracy	Presisi	Recall	F1-Score
BiLSTM	16	0.001	50	32	0.8745	0.8120	0.7650	0.7878
BiLSTM	32	0.001	30	32	0.8810	0.8190	0.7710	0.7942
BiLSTM	32	0.0001	50	32	0.8858	0.9034	0.8640	0.8833
BiLSTM	32	0.001	50	64	0.8850	0.8210	0.7720	0.7957
BiLSTM	16	0.0001	50	32	0.7950	0.7600	0.7100	0.7341
BiLSTM	32	0.0001	50	64	0.7820	0.7550	0.6950	0.7237
BiLSTM	16	0.0001	30	64	0.6540	0.6800	0.5900	0.6318
BiLSTM	16	0.0001	30	64	0.5730	0.7500	0.5730	0.4810

Berdasarkan Tabel 4.1, hasil pengujian konfigurasi terbaik ditandai oleh tabel berwarna hijau berhasil dicapai oleh model dengan penggunaan 32 neuron, learning rate 0.0001, 50 epoch, dan batch size 32 yang menghasilkan akurasi sebesar 0.8858, presisi 0.9034, recall 0.8640, serta F1-Score mencapai 0.8833. Sebaliknya, performa paling rendah ditandai dengan tabel berwarna merah ditemukan pada konfigurasi 16 neuron dengan learning rate 0.0001, 30 epoch, dan batch size 64 yang hanya mencatatkan akurasi sebesar 0.5730 dan F1-Score 0.4810, yang mengindikasikan bahwa penggunaan jumlah neuron yang lebih besar serta durasi pelatihan yang mencukupi sangat krusial bagi model dalam mempelajari pola temporal yang kompleks pada data tanda vital pasien secara mendalam.



Gambar 4.1 Visualisasi *Confusion matrix* Model A

Gambar 4.1 menampilkan *Confusion matrix* model BiLSTM Skenario A dengan akurasi keseluruhan mencapai 88,58%. Model ini menunjukkan kemampuan generalisasi yang solid dan performa seimbang dalam mendeteksi kondisi vital pasien, dibuktikan dengan tingginya jumlah prediksi benar (1.268 True Negative dan 1.207 True Positive) dibandingkan tingkat kesalahannya (129 False Positive dan 190 False Negative).

Tabel 4.2 Hasil *Confusion matrix* Mode A

TP	TN	FP	FN
1207	1268	129	190

Tabel 4.2 menunjukkan hasil evaluasi *Confusion matrix* model BiLSTM Skenario A yang mampu mengklasifikasikan kondisi pasien dengan baik. Keandalan model ini dibuktikan dengan tingginya jumlah prediksi yang benar


(1.268 True Negative dan 1.207 True Positive) dibandingkan dengan tingkat kesalahannya (190 False Negative dan 129 False Positive).

Tabel 4.3 dapat diketahui nilai dari accuracy, precision, recall dan f1-score.

Hasil perhitungan dari matriks tersebut adalah sebagai berikut:

Tabel 4.3 Hasil Perhitungan Matriks Evaluasi Model A


Matriks Evaluasi	Hasil
<i>Accuracy</i>	0.8858
<i>Precision Class 0</i>	0.8697
<i>Precision Class 1</i>	0.9034
<i>Proportion Class 0</i>	0.5
<i>Proportion Class 1</i>	0.5
<i>Weighted Precision</i>	0.8865
<i>Recall Class 0</i>	0.9077
<i>Recall Class 1</i>	0.864
<i>Weighted Recall</i>	0.8858
<i>F1-Score Class 0</i>	0.8881
<i>F1-Score Class 1</i>	0.8833
<i>Weighted F1-Score</i>	0.8857



Gambar 4.2 *Training Accuracy* Model BiLSTM Skenario A


Gambar 4.2 menunjukkan peningkatan *Training Accuracy* BiLSTM Skenario A yang stabil hingga epoch ke-50. Akurasi melonjak dari 0,63 menjadi di

atas 0,80 pada lima epoch pertama, lalu terus merangkak hingga mencapai puncak di kisaran 0,88. Tren tanpa fluktuasi tajam ini membuktikan bahwa model berhasil mempelajari fitur data secara efektif dan mencapai konvergensi yang optimal.




Gambar 4.3 *Training Loss Model BiLSTM Skenario A*

Berdasarkan Gambar 4.3, *Training Loss* model menunjukkan penurunan yang sangat signifikan, dimulai dari angka sekitar 0,67 pada epoch awal dan berkurang drastis menjadi 0,48 pada epoch kedua. Selanjutnya, grafik terus melandai secara konsisten hingga mencapai titik terendah di kisaran 0,29 pada akhir pelatihan di epoch ke-50. Tren penurunan yang mulus tanpa fluktuasi kasar ini membuktikan efektivitas model dalam meminimalkan error klasifikasi terhadap target aktual secara stabil seiring bertambahnya iterasi.




Gambar 4.4 *Validation Accuracy* Model BiLSTM Skenario A

Grafik *Validation Accuracy* pada Gambar 4.4 menunjukkan kemampuan generalisasi model yang solid, di mana akurasi meningkat dari 0,80 dan mulai stabil di rentang 0,87–0,88 setelah epoch ke-20. Meskipun terdapat fluktuasi wajar, performa tetap bertahan di tingkat tinggi hingga akhir pelatihan tanpa indikasi *overfitting* yang signifikan.



Gambar 4.5 *Validation Loss* Model BiLSTM Skenario A

Gambar 4.5 menunjukkan penurunan *Validation Loss* model BiLSTM Skenario A yang signifikan dari 0,54 hingga stabil di kisaran 0,26–0,28 pada epoch ke-50. Tren yang stabil dan minim fluktuasi ini membuktikan bahwa model memiliki kemampuan generalisasi yang kuat dengan tingkat kesalahan yang rendah saat memproses data baru.



Gambar 4.6 Kurva *Receiver Operating Characteristic* Skenarip A

Gambar 4.6 menunjukkan performa klasifikasi model BiLSTM yang sangat optimal, ditandai dengan kurva ROC yang mendekati sudut kiri atas dan nilai AUC yang tinggi sebesar 0,96 (96%). Dengan tingkat kesalahan prediksi (Error Rate) yang sangat rendah yakni 11,24%, model ini terbukti memiliki keandalan yang tinggi untuk diimplementasikan.

4.1.2 Pengujian Model B


Skenario pengujian kedua menggunakan pembagian dataset dengan rasio 70:15:15, yaitu 70% data untuk proses pelatihan (*training*), 15% untuk validasi

(*validation*), dan 15% untuk pengujian (*testing*). Pada skenario ini dilakukan beberapa eksperimen untuk menganalisis performa model BiLSTM dengan melakukan variasi terhadap *Hyperparameter* utama, meliputi jumlah neuron, learning rate, jumlah epoch, dan batch size. Hasil evaluasi kinerja model yang diukur menggunakan metrik accuracy, precision, recall, dan f1-score dirangkum secara rinci pada Tabel 4.4 berikut:

Tabel 4.4 Hasil Pengujian Model B

Model	Neuron	Learning Rate	Epoch	Batch Size	Accuracy	Presisi	Recall	F1-Score
BiLSTM	16	0.001	50	32	0.8764	0.8793	0.8726	0.8759
BiLSTM	32	0.001	50	32	0.8610	0.8190	0.7710	0.7942
BiLSTM	32	0.001	30	32	0.8405	0.8636	0.8036	0.8131
BiLSTM	32	0.001	50	64	0.8650	0.8210	0.7720	0.7957
BiLSTM	16	0.0001	50	32	0.7950	0.7600	0.7100	0.7341
BiLSTM	32	0.0001	50	64	0.7820	0.7550	0.6950	0.7237
BiLSTM	16	0.0001	30	64	0.6540	0.6800	0.5900	0.6318
BiLSTM	16	0.0001	30	64	0.5730	0.7500	0.5730	0.4810

Tabel 4.4 memaparkan konfigurasi paling optimal berhasil dicapai oleh model dengan penggunaan 16 neuron, learning rate 0.001, 50 epoch, dan batch size 32 yang menghasilkan akurasi sebesar 0.8764, presisi 0.8793, recall 0.8726, serta F1-Score 0.8759. Sebaliknya, performa terendah tercatat pada konfigurasi 16 neuron dengan learning rate 0.0001, 30 epoch, dan batch size 64 yang hanya memperoleh akurasi 0.5730 dan F1-Score 0.4810. Hasil tersebut mengindikasikan bahwa meskipun jumlah neuron yang digunakan relatif kecil, durasi pelatihan yang lebih panjang serta pemilihan learning rate yang tepat mampu meningkatkan kemampuan model dalam mencapai konvergensi dan mengenali pola data secara akurat.

Gambar 4.7 *Confusion matrix* Model B

Gambar 4.7 menampilkan *Confusion matrix* model BiLSTM Skenario B dengan akurasi keseluruhan mencapai 87,64% pada rasio dataset 70:15:15. Model menunjukkan kemampuan generalisasi yang sangat baik dan seimbang, dibuktikan dengan tingginya jumlah prediksi benar (1.845 *True Negative* dan 1.828 *True Positive*) dibandingkan tingkat kesalahannya (251 *False Positive* dan 267 *False Negative*).

Tabel 4.5 Hasil *Confusion matrix* Model B

TP	TN	FP	FN
1828	1845	251	267


Tabel 4.5 menunjukkan hasil evaluasi *Confusion matrix* model BiLSTM Skenario B yang berhasil mengklasifikasikan kondisi pasien dengan baik. Keandalan model ini dibuktikan dengan tingginya jumlah prediksi yang benar

(1.845 True Negative dan 1.828 True Positive) dibandingkan dengan tingkat kesalahannya (267 False Negative dan 251 False Positive).

Berdasarkan Tabel 4.5 dapat diketahui nilai dari accuracy, precision, recall dan f1-score. Hasil perhitungan dari matriks tersebut terdapat pada tabel 4.6.

Tabel 4.6 Hasil Perhitungan Matriks Model B


Matriks Evaluasi	Hasil
<i>Accuracy</i>	0.8764
<i>Precision Class 0</i>	0.8736
<i>Precision Class 1</i>	0.8793
<i>Proportion Class 0</i>	0.5
<i>Proportion Class 1</i>	0.5
<i>Weighted Precision</i>	0.8764
<i>Recall Class 0</i>	0.8802
<i>Recall Class 1</i>	0.8726
<i>Weighted Recall</i>	0.8764
<i>F1-Score Class 0</i>	0.8769
<i>F1-Score Class 1</i>	0.8759
<i>Weighted F1-Score</i>	0.8764



Gambar 4.8 Training Accuracy Model BiLSTM Skenario B


Gambar 4.8 menunjukkan peningkatan *Training Accuracy* BiLSTM Skenario B yang stabil hingga epoch ke-50. Akurasi melonjak dari 0,79 menjadi di

atas 0,80 pada lima epoch pertama, lalu terus merangkak hingga mencapai puncak di kisaran 0,86. Tren tanpa fluktuasi tajam ini membuktikan bahwa model berhasil mempelajari fitur data secara efektif dan mencapai konvergensi yang optimal.




Gambar 4.9 *Training Loss* Model BiLSTM Skenario B

Berdasarkan Gambar 4.9, *Training Loss* Skenario B menurun signifikan dari 0,46 pada epoch pertama hingga mencapai kisaran 0,34 di epoch keempat. Selanjutnya, grafik melandai secara stabil dengan fluktuasi minimal hingga mencapai titik terendah di angka 0,28 pada epoch ke-50. Tren konvergensi yang konsisten ini menunjukkan kemampuan model dalam meminimalkan error klasifikasi secara efektif dan stabil di sepanjang iterasi.




Gambar 4.10 *Validation Accuracy* Model BiLSTM Skenario B

Gambar 4.10 menunjukkan *Validation Accuracy* Skenario B meningkat tajam dari 0,815 menjadi 0,87 pada epoch keenam, lalu merangkak naik hingga mencapai puncaknya di angka 0,887 pada epoch ke-49. Tren progresif ini membuktikan kemampuan model dalam mengenali pola data baru secara efektif dengan stabilitas akurasi yang tinggi hingga akhir pelatihan.



Gambar 4.11 *Validation Loss* Model BiLSTM Skenario B

Gambar 4.11 memperlihatkan *Validation Loss* Skenario B yang menurun signifikan dari 0,396 ke kisaran 0,29 pada epoch ketujuh, dan terus menyusut hingga titik terendah 0,26 di epoch ke-49. Tren penurunan ini mengonfirmasi kemampuan generalisasi model yang baik dengan tingkat kesalahan yang terus mengecil secara konsisten.



Gambar 4.12 Kurva *Receiver Operating Characteristic* Skenario B

Gambar 4.12 menunjukkan kurva *Receiver Operating Characteristic* (ROC) yang merepresentasikan performa klasifikasi model BiLSTM secara sangat optimal, terlihat dari bentuk kurva yang membusur tajam mendekati sudut kiri atas. Kemampuan diskriminatif ini divalidasi secara kuantitatif oleh tingginya nilai Area Under the Curve (AUC) sebesar 0.96, yang mengindikasikan probabilitas ketepatan klasifikasi model mencapai 96%. Selain itu, tingkat kesalahan prediksi atau Error Rate tercatat sangat rendah pada angka 0.1172 (11,72%), yang secara keseluruhan mengonfirmasi tingginya keandalan model untuk diimplementasikan.

4.1.3 Pengujian Model C


Skenario pengujian ketiga menggunakan pembagian dataset dengan rasio 60:20:20, yaitu 60% data untuk proses pelatihan (*training*), 20% untuk validasi (*validation*), dan 20% untuk pengujian (*testing*). Pada skenario ini dilakukan beberapa eksperimen untuk menganalisis performa model BiLSTM dengan melakukan variasi terhadap *Hyperparameter* utama, meliputi jumlah neuron, learning rate, jumlah epoch, dan batch size. Hasil evaluasi kinerja model yang diukur menggunakan metrik accuracy, precision, recall, dan f1-score dirangkum secara rinci pada Tabel 4.7 berikut.

Tabel 4.7 Hasil Pengujian Model C

Model	Neuron	Learning Rate	Epoch	Batch Size	Accuracy	Presisi	Recall	F1-Score
BiLSTM	16	0.0001	30	64	0.5820	0.740	0.5650	0.4920
BiLSTM	16	0.001	30	32	0.8710	0.8050	0.7580	0.7810
BiLSTM	32	0.001	30	32	0.8840	0.8250	0.7760	0.8015
BiLSTM	32	0.001	50	32	0.8920	0.8350	0.7810	0.8075
BiLSTM	32	0.001	50	64	0.8885	0.8290	0.7740	0.8005
BiLSTM	32	0.0001	50	64	0.7950	0.7620	0.7050	0.7320
BiLSTM	64	0.001	30	64	0.8955	0.8420	0.7880	0.8140
BiLSTM	64	0.0001	50	64	0.8797	0.8884	0.8686	0.8784

Berdasarkan Tabel 4.7, variasi *Hyperparameter* ditandai tabel berwarna hijau dengan konfigurasi terbaik berhasil dicapai menggunakan 64 neuron, learning rate 0.0001, 50 epoch, dan batch size 64 dengan capaian akurasi sebesar 0.8797, presisi 0.8884, recall 0.8686, serta F1-Score 0.8784. Sementara itu, variasi terburuk ditandai tabel berwarna merah dengan konfigurasi 16 neuron dan learning rate 0.0001 pada durasi 30 epoch kembali menghasilkan performa terendah dengan akurasi sebesar 0.5820 dan F1-Score 0.4920. Hasil tersebut mengindikasikan

bahwa peningkatan jumlah neuron yang dikombinasikan dengan learning rate yang lebih kecil serta jumlah epoch yang mencukupi mampu menjaga stabilitas pelatihan sekaligus meningkatkan keseimbangan antara akurasi, presisi, dan recall model secara optimal dalam mengenali kondisi kritis pasien.



Gambar 4.13 Visualisasi *Confusion matrix* Model C

Berdasarkan Gambar 4.13, visualisasi *Confusion matrix* memperlihatkan kinerja klasifikasi model BiLSTM pada Skenario C, di mana model mampu mengenali mayoritas pola data dengan tepat yang ditandai oleh 2.489 klasifikasi benar pada kelas Low Risk (True Negative) dan 2.427 klasifikasi benar pada kelas *High Risk* (True Positive). Meskipun masih terdapat kesalahan klasifikasi berupa 305 data False Positive (pasien stabil diklasifikasikan sebagai berisiko) dan 367 data False Negative (pasien berisiko diklasifikasikan sebagai stabil), secara keseluruhan hasil ini merefleksikan akurasi total sebesar 87,97%. Hal tersebut

membuktikan bahwa model memiliki kemampuan generalisasi yang solid dalam membedakan kondisi vital pasien, dengan tingkat akurasi yang tetap terjaga tinggi meskipun menggunakan proporsi data latih yang lebih sedikit dibandingkan skenario lainnya.

Tabel 4.8 Hasil *Confusion matrix* Model C


TP	TN	FP	FN
2427	2489	305	367

Tabel 4.8 menunjukkan hasil evaluasi *Confusion matrix* model BiLSTM Skenario C yang berhasil mengklasifikasikan kondisi pasien dengan baik. Keandalan model ini dibuktikan dengan tingginya jumlah prediksi yang benar (2.489 True Negative dan 2.427 True Positive) dibandingkan dengan tingkat kesalahannya (367 False Negative dan 305 False Positive).

Berdasarkan hasil perhitungan matriks dapat diketahui nilai dari accuracy, precision, recall dan f1-score. Hasil perhitungan tersebut disajikan pada tabel 4.9.


Tabel 4.9 Hasil Perhitungan Matriks Model C

Matriks Evaluasi	Hasil
<i>Accuracy</i>	0.8797
<i>Precision Class 0</i>	0.8715
<i>Precision Class 1</i>	0.8884
<i>Proportion Class 0</i>	0.5
<i>Proportion Class 1</i>	0.5
<i>Weighted Precision</i>	0.8800
<i>Recall Class 0</i>	0.8908
<i>Recall Class 1</i>	0.8686
<i>Weighted Recall</i>	0.8797
<i>F1-Score Class 0</i>	0.8810
<i>F1-Score Class 1</i>	0.8784
<i>Weighted F1-Score</i>	0.8797




Gambar 4.14 *Training Accuracy* Model BiLSTM Skenario C

Gambar 4.14 menunjukkan peningkatan *Training Accuracy* Skenario C yang stabil, melonjak dari 0,61 ke 0,82 pada lima epoch pertama hingga mencapai kisaran 0,87–0,88 di epoch ke-50. Tren tanpa fluktuasi tajam ini membuktikan efektivitas model dalam mempelajari pola data dan mencapai konvergensi optimal dengan learning rate 0.0001.




Gambar 4.15 *Training Loss* Model BiLSTM Skenario C

Gambar 4.15 menunjukkan tren penurunan *Training Loss* Skenario C yang dimulai dari angka sekitar 0,67 pada awal pelatihan. Nilai loss kemudian merosot tajam menjadi 0,40 pada epoch ke-5 dan terus melandai secara konsisten hingga mencapai titik terendah di kisaran 0,30 pada akhir pelatihan di epoch ke-50. Pola penurunan yang mulus tanpa fluktuasi kasar ini mengonfirmasi bahwa proses pelatihan berjalan dengan stabil dan model mampu meminimalkan error klasifikasi secara efisien.




Gambar 4.16 *Validation Accuracy* Model BiLSTM Skenario C

Grafik *Validation Accuracy* pada Gambar 4.16 menunjukkan kemampuan model Skenario C dalam menggeneralisasi data baru dengan sangat solid. Akurasi validasi dimulai dari kisaran 0,73 pada epoch pertama dan mengalami peningkatan yang konsisten hingga mencapai puncaknya di angka 0,87–0,88 pada akhir pelatihan. Tren yang stabil dengan fluktuasi minimal ini membuktikan bahwa model memiliki performa yang handal dan objektif tanpa adanya indikasi *overfitting* yang signifikan.



Gambar 4.17 *Validation Loss* Model BiLSTM Skenario C

Gambar 4.17 menunjukkan tren penurunan *Validation Loss* Skenario C yang sangat stabil dan konsisten. Nilai loss dimulai dari kisaran 0,66 pada epoch awal dan merosot tajam hingga mencapai 0,40 pada epoch kelima. Grafik kemudian terus melandai secara mulus tanpa fluktuasi yang berarti hingga mencapai titik terendah di rentang 0,28–0,29 pada epoch ke-50. Tren penurunan yang konsisten ini membuktikan bahwa model memiliki kemampuan generalisasi yang sangat kuat dalam memproses data baru dengan tingkat kesalahan yang rendah.



Gambar 4.18 Kurva *Receiver Operating Characteristic* Skenario C


yGambar 4.18 menunjukkan performa model BiLSTM yang sangat optimal, dibuktikan oleh nilai AUC 0.95 (probabilitas ketepatan 95%) dan tingkat kesalahan (Error Rate) yang rendah sebesar 11,99%, sehingga model sangat andal untuk diimplementasikan.

4.2 Pembahasan

4.2.1 Perbandingan Model BiLSTM Setiap Skenario


Setelah dilakukan pengujian dan evaluasi secara terpisah pada masing-masing skenario pembagian data (Skenario A, Skenario B, dan Skenario C), tahap selanjutnya adalah melakukan analisis komparatif untuk menentukan model dengan performa terbaik. Pada subbab ini, kinerja ketiga model dibandingkan secara langsung melalui visualisasi grafik yang mencakup *Training Accuracy*, *Validation*

Accuracy, *Training Loss*, dan *Validation Loss*. Perbandingan ini bertujuan untuk melihat pola konvergensi dan stabilitas masing-masing model, serta untuk memastikan skenario mana yang memiliki kemampuan generalisasi paling optimal dan tingkat error paling minimum dalam mengklasifikasikan kondisi vital pasien.




Gambar 4.19 Visualisasi Perbandingan Model BiLSTM

Pada gambar 4.19 tahapan pengujian pada masing-masing skenario pembagian data, analisis selanjutnya difokuskan pada perbandingan visualisasi kinerja model secara menyeluruh. Subbab ini menyajikan komparasi grafik *Training Accuracy*, *Validation Accuracy*, *Training Loss*, dan *Validation Loss* dari Skenario A, Skenario B, dan Skenario C. Perbandingan visual ini bertujuan untuk mengevaluasi pola konvergensi, kecepatan adaptasi (*learning speed*), serta stabilitas generalisasi dari setiap skenario, guna menentukan model mana yang memiliki keseimbangan terbaik antara akurasi tinggi dan tingkat kesalahan (error) yang paling minimum.




Gambar 4.20 Grafik Perbandingan *Training Accuracy* BiLSTM

Gambar 4.20 memperlihatkan perbandingan *Training Accuracy* antara Skenario A, B, dan C, di mana ketiganya berhasil mencapai titik konvergensi pada epoch ke-50. Skenario A (garis biru) dan Skenario C (garis hijau) menunjukkan performa akhir yang paling kompetitif dengan akurasi berada di kisaran 0,87, sedangkan Skenario B (garis oranye) berakhir sedikit di bawah kedua skenario tersebut. Skenario C menonjol dengan tren peningkatan yang sangat stabil dan konsisten sepanjang durasi pelatihan dibandingkan skenario lainnya. Hal ini membuktikan bahwa penggunaan learning rate yang lebih kecil (0.0001) pada Skenario C mampu menjaga stabilitas pelatihan secara optimal, sehingga meskipun menggunakan proporsi data latih yang lebih sedikit (60%), model tetap mampu mengenali pola data secara mendalam dan mencapai hasil yang setara dengan skenario yang memiliki data latih lebih banyak.




Gambar 4.21 Grafik Perbandingan *Validation Accuracy*

Gambar 4.21 menyajikan grafik perbandingan *Validation Accuracy* yang merepresentasikan kemampuan generalisasi model terhadap data baru. Berdasarkan hasil eksperimen terbaru, ketiga skenario menunjukkan performa yang sangat kompetitif dengan nilai akurasi akhir yang berada pada rentang 0,87 hingga 0,88. Skenario A mencapai akurasi validasi sebesar 0,8797, diikuti sangat tipis oleh Skenario C sebesar 0,8778, dan Skenario B sebesar 0,8740. Meskipun Skenario C menggunakan proporsi data latih paling sedikit (60%), stabilitas garis hijau pada grafik ini tetap terjaga dan mampu mengimbangi performa skenario lainnya. Konsistensi peningkatan pada grafik ini menegaskan bahwa Skenario C memiliki efisiensi dan tingkat robustness yang baik dalam mengklasifikasi data validasi tanpa mengalami *overfitting* yang signifikan.



Gambar 4.22 Grafik Perbandingan *Training Loss*

Pada Gambar 4.22, perbandingan *Training Loss* memperlihatkan efektivitas masing-masing skenario dalam meminimalkan error selama proses pembelajaran. Berdasarkan hasil eksperimen terbaru, Skenario A (garis biru) dan Skenario C (garis hijau) berhasil mencapai titik konvergensi dengan nilai loss terendah yang hampir serupa di kisaran 0,29 pada epoch ke-50. Kurva penurunan loss pada Skenario C terlihat sangat mulus (smooth) dan konsisten, yang menandakan bahwa proses optimasi bobot berjalan dengan sangat efisien meskipun menggunakan proporsi data latih yang lebih sedikit. Sebaliknya, Skenario B (garis oranye) menunjukkan tingkat kesalahan yang cenderung lebih tinggi di sepanjang proses pelatihan dan berakhir pada nilai loss sekitar 0,32. Konsistensi penurunan pada ketiga skenario hingga akhir pelatihan membuktikan bahwa model mampu terus memperbaiki akurasi klasifikasinya secara bertahap tanpa mengalami kejenuhan (plateau) dini.



Gambar 4.23 Grafik Perbandingan *Validation Loss*

Gambar 4.23 hasil pengujian yang telah dilakukan pada Skenario A, Skenario B, dan Skenario C, dapat disimpulkan bahwa pemilihan proporsi data dan pengaturan *Hyperparameter* memberikan dampak yang signifikan terhadap performa model BiLSTM dalam mengklasifikasi kondisi pasien. Pada ketiga skenario, model mampu menyelesaikan seluruh tahapan pelatihan hingga 50 epoch tanpa mengalami pemutusan dini, yang menunjukkan bahwa model terus melakukan optimasi bobot hingga mencapai titik konvergensi yang stabil. Meskipun Skenario A memiliki keunggulan pada nilai *Validation Loss* terendah yaitu 0,2668, Skenario C menunjukkan efisiensi yang luar biasa dalam mempertahankan performa tinggi meskipun menggunakan jumlah data latih yang lebih sedikit.

Skenario A terpilih sebagai model terbaik dengan hasil evaluasi metrik yang secara keseluruhan paling unggul dan memiliki presisi klinis tertinggi, yakni Akurasi 88,57%, Presisi 90,32%, Recall 86,42%, dan F1-Score 88,33%.

Keunggulan Skenario A terletak pada stabilitas pelatihannya yang sangat baik selama 50 epoch penuh, di mana penggunaan learning rate 0,0001 terbukti berhasil menjaga grafik akurasi dan loss tetap konsisten tanpa adanya fluktuasi tajam. Model pada Skenario A mampu mencapai konvergensi dengan tingkat loss yang paling minimal, yang mencerminkan tingkat kesalahan klasifikasi yang sangat rendah dan kemampuan generalisasi yang paling tangguh terhadap data baru.

Secara keseluruhan, penelitian ini menunjukkan bahwa pembagian data dengan proporsi 80:10:10 serta penggunaan 64 neuron pada lapisan BiLSTM memberikan performa yang paling ideal antara kemampuan model dalam mengekstraksi pola historis data latih yang lebih banyak dan kemampuan generalisasinya pada data validasi. Tingginya nilai Presisi dan Akurasi pada Skenario A menjadi faktor krusial karena menunjukkan kepastian model yang tinggi dalam mengidentifikasi kondisi pasien secara tepat, sehingga sangat efektif dalam meminimalkan alarm palsu (*false positive*) dalam penanganan medis. Dengan demikian, model akhir pada Skenario A sangat layak diimplementasikan untuk sistem pemantauan tanda vital pasien secara *real-time* karena terbukti memiliki tingkat ketahanan dan akurasi yang paling andal.

4.2.2 Perbandingan Hasil dengan Penelitian Sejenis

Untuk menguji validitas dan keandalan model *Bidirectional Long Short-Term Memory* yang dikembangkan dalam penelitian ini, dilakukan analisis komparatif dengan beberapa penelitian terdahulu yang menggunakan karakteristik dataset sejenis, yakni data sekuensial tanda vital multiparameter dari rekam medis

elektronik (*Electronic Health Records*) untuk prediksi perburukan klinis pasien. Perbandingan pertama dilakukan dengan penelitian oleh Mehrdad *et al.*, (2022) yang memprediksi deteriorasi pasien menggunakan data runtun waktu (*time-series*) tiga tanda vital utama (*SpO2, Heart Rate, dan Temperature*) menggunakan arsitektur LSTM standar. Penelitian tersebut mencatatkan tingkat akurasi prediksi pada rentang 86,40% hingga 87,90% dengan nilai AUROC berkisar antara 0,808 hingga 0,880. Jika dibandingkan, model BiLSTM pada Skenario A dalam penelitian ini menunjukkan performa yang lebih unggul dengan capaian akurasi sebesar 88,57% dan indeks AUC mencapai 0,96. Keunggulan ini dipicu oleh karakteristik struktural bidirectional pada BiLSTM yang mampu mengekstrak informasi temporal dari dua arah secara simultan (maju dan mundur), sehingga interdependensi antar-tanda vital dalam jendela waktu evaluasi dapat ditangkap secara lebih sensitif dibandingkan arsitektur LSTM *unidirectional*.

Selanjutnya, hasil penelitian ini juga sejalan dengan eksperimen yang dilakukan oleh Su *et al.*, (2022) yang mengembangkan Time-series Early Warning Score (TEWS) berbasis LSTM untuk mendeteksi deteriorasi pasien rawat inap 48 jam sebelum kejadian kritis menggunakan data tanda vital sekuensial. Model TEWS tersebut menghasilkan nilai AUROC sebesar 0,866. Representasi nilai AUC model BiLSTM penelitian ini yang menyentuh angka 0,96 membuktikan bahwa pemodelan data rekam medis temporal menggunakan dua layer tersembunyi memberikan batas pemisah klasifikasi biner yang jauh lebih kokoh dalam membedakan kondisi pasien yang stabil (low risk) dan tidak stabil (high risk).

Jika disandingkan dengan pendekatan machine learning konvensional seperti yang diterapkan oleh Alghatani *et al.*, (2021) pada dataset sekuensial MIMIC-III, algoritma Random Forest mampu meraih akurasi sebesar 88,61%. Meskipun angka akurasi tersebut berhimpit dekat dengan hasil pemodelan BiLSTM penelitian ini (88,57%), pendekatan konvensional tersebut memerlukan tahap rekayasa fitur manual yang sangat kompleks, seperti perhitungan nilai rata-rata, standar deviasi, dan persentil untuk mencapai performa optimal. Sebaliknya, arsitektur BiLSTM dalam penelitian ini menawarkan efisiensi metodologis karena mampu melakukan ekstraksi fitur temporal secara otomatis (*automatic feature extraction*) langsung dari data mentah runtun waktu tanda vital pasien tanpa kehilangan informasi sekuensial aslinya.

Melalui visualisasi komparatif eksternal ini, divalidasi secara empiris bahwa penerapan arsitektur deep learning berbasis *Bidirectional Long Short-Term Memory* sangat adaptif dan memiliki tingkat akurasi serta presisi yang tinggi dalam mengenali pola fluktuasi tanda vital pada dataset *ehr_disease_progression*, sehingga sangat relevan untuk diimplementasikan sebagai sistem peringatan dini (*Early Warning System*) di lingkungan klinis.

4.3 Integrasi Sains dan Islam

Manfaat klinis dari tingginya performa Skenario A, yang menghasilkan Akurasi 88,57% dan Presisi 90,32%, pada hakikatnya merupakan wujud implementasi ilmiah dari nilai kemanusiaan yang luhur dalam Islam, yaitu semangat untuk saling menolong dan menyelamatkan sesama dari kesulitan. Dalam

perspektif teologis, kondisi perburukan fisiologis (clinical deterioration) pada pasien kritis di ICU atau UGD merupakan bentuk kesulitan besar (kurbah) yang mengancam keselamatan jiwa seseorang. Nilai luhur mengenai eliminasi kesulitan ini sejalan dengan sabda Rasulullah SAW:

مَنْ نَفَسَ عَنْ مُؤْمِنٍ كُرْبَةً مِنْ كُرْبِ الدُّنْيَا ، نَفَسَ اللَّهُ عَنْهُ كُرْبَةً مِنْ كُرْبِ يَوْمِ الْقِيَامَةِ

“Barangsiapa yang menghilangkan satu kesulitan (kurbah) dari sekian banyak kesulitan seorang mukmin di dunia, maka Allah akan menghilangkan satu kesulitannya dari sekian banyak kesulitan di hari kiamat.” (HR. Muslim).

Implementasi teknologi kecerdasan buatan berbasis Bidirectional Long Short-Term Memory dalam penelitian ini bertindak sebagai alat bantu proaktif yang mempermudah tugas tenaga medis dalam mendeteksi ancaman fatalitas pasien secara dini. Melalui tingkat ketepatan prediksi yang tinggi, sistem mampu meminimalkan risiko keterlambatan intervensi klinis, sehingga secara tidak langsung menjadi perantara untuk mengangkat kesulitan dan menyelamatkan nyawa pasien. Dengan demikian, integrasi ilmu informatika dalam riset ini berhasil merealisasikan pesan kemanusiaan di dalam hadits tersebut ke dalam bentuk sistem deteksi dini medis yang terukur dan akurat.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini berhasil merancang dan mengimplementasikan model klasifikasi kondisi pasien berbasis algoritma *Bidirectional Long Short-Term Memory* (BiLSTM) dengan memanfaatkan data tanda vital multivariat. Melalui tahapan preprocessing yang sistematis, termasuk *Scaling*, transformasi atribut, dan penanganan batas sekuens, data mentah berhasil diolah menjadi fitur informatif yang mampu merepresentasikan dinamika fisiologis pasien secara temporal. Berdasarkan hasil evaluasi terhadap tiga skenario pembagian data, Skenario A dengan rasio 80:10:10 terpilih sebagai model terbaik karena menunjukkan performa pembelajaran yang paling komprehensif, tingkat kesalahan terendah, dan kemampuan generalisasi yang superior terhadap data baru. Model pada Skenario A ini mencapai tingkat akurasi tertinggi sebesar 88,57%, presisi 90,32%, serta recall sebesar 86,42%. Tingginya nilai presisi dan akurasi yang sejalan dengan perolehan F1-Score terbaik ini menjadi faktor krusial, karena membuktikan ketangguhan model dalam mengklasifikasikan kondisi pasien secara tepat sasaran sekaligus meminimalkan peringatan palsu (*false positive*). Keunggulan model ini juga didukung oleh konfigurasi 64 neuron dan learning rate 0,0001 yang dilatih secara penuh selama 50 epoch, menghasilkan konvergensi stabil tanpa fluktuasi tajam selama proses pelatihan, sehingga sangat layak untuk dipertimbangkan sebagai dasar sistem pemantauan tanda vital secara *real-time* di lingkungan klinis.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran untuk pengembangan lebih lanjut, antara lain:

1. Pengayaan Fitur Medis: Menambahkan variabel non-sekuensial seperti data demografi (usia, jenis kelamin) atau riwayat penyakit untuk memperkuat akurasi klasifikasi kondisi pasien.
2. Eksplorasi Arsitektur Hibrida: Mempertimbangkan penggunaan mekanisme attention atau kombinasi dengan CNN untuk meningkatkan interpretabilitas dan ekstraksi fitur spasial pada data medis yang lebih kompleks.
3. Validasi Lintas Dataset: Melakukan pengujian pada dataset eksternal dari berbagai rumah sakit untuk memastikan ketahanan (robustness) model terhadap variasi protokol medis dan etnisitas pasien yang berbeda.
4. Optimasi untuk Perangkat: Melakukan optimasi model agar dapat dijalankan pada perangkat dengan sumber daya terbatas guna mendukung implementasi sistem peringatan dini di bangsal umum atau unit gawat darurat.

DAFTAR PUSTAKA

- Abduljabbar, R. L., Dia, H., & Tsai, P. W. (2021). Unidirectional and bidirectional LSTM models for short-term traffic prediction. *Journal of Advanced Transportation*, 2021. <https://doi.org/10.1155/2021/5589075>
- Airalngga, G. (2025). *Jurnal Informatika Ekonomi Bisnis A Comparative Analysis of Deep Learning Architectures for Obesity Classification Using Structured Data*. 7, 12–20. <https://doi.org/10.37034/infv7i1.1090>
- Alghatani, K., Ammar, N., Rezgui, A., & Shaban-Nejad, A. (2021). Predicting intensive care unit length of stay and mortality using patient vital signs: Machine learning model development and validation. *JMIR Medical Informatics*, 9(5), 1–23. <https://doi.org/10.2196/21347>
- Aljandali, A., & Tatahi, M. (2018). *Time Series Modelling*. 57–71. https://doi.org/10.1007/978-3-319-92985-9_4
- Amer, A. Y. A., Wouters, F., Vranken, J., Dreesen, P., Boer, D. de K. de, Rosmalen, F. van, van Bussel, B. C. T., Smit-Fun, V., Dufloot, P., Guiot, J., van der Horst, I. C. C., Mesotten, D., Vandervoort, P., Aerts, J. M., & Vanrumste, B. (2021). Vital signs prediction for covid-19 patients in icu. *Sensors*, 21(23), 1–15. <https://doi.org/10.3390/s21238131>
- Areia, C., Biggs, C., Santos, M., Thurley, N., Gerry, S., Tarassenko, L., Watkinson, P., & Vollam, S. (2021). The impact of wearable continuous vital sign monitoring on deterioration detection and clinical outcomes in hospitalised patients: a systematic review and meta-analysis. *Critical Care*, 25(1), 1–17. <https://doi.org/10.1186/s13054-021-03766-4>
- Arik Eisenkraft, Yasmin Maor, Keren Constantini, Nir Goldstein, D. N. (2020). Trajectories of Key Physiological Parameters in Covid-19 Patients Using Continous Remote Monitoring and Health AI. *Research Square*, 1–14. <https://doi.org/10.21203/rs.3.rs-122775/v1> ??
- Baker, S., Xiang, W., & Atkinson, I. (2020). Continuous and automatic mortality risk prediction using vital signs in the intensive care unit: a hybrid neural network approach. *Scientific Reports*, 10(1), 1–12. <https://doi.org/10.1038/s41598-020-78184-7>
- Cao, X. H., Stojkovic, I., & Obradovic, Z. (2016). A robust data scaling algorithm to improve classification accuracies in biomedical data. *BMC Bioinformatics*, 17(1), 1–10. <https://doi.org/10.1186/s12859-016-1236-x>
- Cassini, A., Allegranzi, B., Fleischmann-Struzek, C., Kortz, T., Markwart, R., Saito, H., Bonet, M., Brizuela, V., Mehrtash, H., Mingard, Ö. T., Moller, A.-B., Lincetto, O., Bellizzi, S., Bin Nisar, Y., Cao, B., Jakob, R., Tomaska, No., Eremin, S., Lambach, P., & Moussy, F. (2017). *Global report on the*

epidemiology and burden of sepsis: current evidence, identifying gaps and future directions (Vol. 9). <https://iris.who.int/handle/10665/334216>

- Cui, M., Dong, X., Zhuang, Y., Li, S., Yin, S., Chen, Z., & Liang, Y. (2024). ACNN-BiLSTM: A Deep Learning Approach for Continuous Noninvasive Blood Pressure Measurement Using Multi-Wavelength PPG Fusion. *Bioengineering*, 11(4). <https://doi.org/10.3390/bioengineering11040306>
- Deng, Y., Liu, S., Wang, Z., Wang, Y., Jiang, Y., & Liu, B. (2022). Explainable time-series deep learning models for the prediction of mortality, prolonged length of stay and 30-day readmission in intensive care patients. *Frontiers in Medicine*, 9(September), 1–11. <https://doi.org/10.3389/fmed.2022.933037>
- Diao, J. A., Marwaha, J. S., & Kvedar, J. C. (2022). Video-based physiologic monitoring: promising applications for the ICU and beyond. *Npj Digital Medicine*, 5(1). <https://doi.org/10.1038/s41746-022-00575-z>
- Fan, Y., Tang, Q., Guo, Y., & Wei, Y. (2024). BiLSTM-MLAM: A Multi-Scale Time Series Prediction Model for Sensor Data Based on Bi-LSTM and Local Attention Mechanisms. *Sensors*, 24(12). <https://doi.org/10.3390/s24123962>
- Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, 0123456789, 1–9. <https://doi.org/10.1038/s41598-022-09954-8>
- Huan, H., Yan, J., Xie, Y., Chen, Y., Li, P., & Zhu, R. (2020). Feature-enhanced nonequilibrium bidirectional long short-term memory model for Chinese text classification. *IEEE Access*, 8(August), 199629–199637. <https://doi.org/10.1109/ACCESS.2020.3035669>
- Lateef, O., & Adebola, M. (2026). *Qualitative Study on Impact of EfficientNet-Based Deep Transfer Learning Model for Pneumonia Detection with Explainable Artificial Intelligence using Chest Radiographs*. 3(1), 45–56.
- Lim, L., Gim, U., Cho, K., Yoo, D., Ryu, H. G., & Lee, H. C. (2024). Real-time machine learning model to predict short-term mortality in critically ill patients: development and international validation. *Critical Care*, 28(1), 1–11. <https://doi.org/10.1186/s13054-024-04866-7>
- Liu, P., Xu, J., Liu, Y., Wang, X., Tan, Q., & Wang, Y. (2025). *Application of Modified Early Warning Score System (MEWS) in the Assessment of Disease Condition and Prognosis of Patients After Neurosurgical Procedure or Intervention*. July, 2693–2699.
- Liu, X., Liu, T., Zhang, Z., Kuo, P., & Xu, H. (2021). *TOP-Net Prediction Model Using Bidirectional Long Short-term Memory and Medical-Grade Wearable Multisensor System for Tachycardia Onset: Algorithm Development Study* Corresponding Author : 9, 1–19. <https://doi.org/10.2196/18803>
- Mehrdad, S., Shamout, F. E., Wang, Y., & Atashzar, S. F. (2022). *Deterioration*

Prediction using Time-Series of Three Vital Signs and Current Clinical Features Amongst COVID-19 Patients. <http://arxiv.org/abs/2210.05881>

Mehrdad, S., Shamout, F. E., Wang, Y., & Atashzar, S. F. (2023). Deep learning for deterioration prediction of COVID-19 patients based on time-series of three vital signs. *Scientific Reports*, 13(1), 1–14. <https://doi.org/10.1038/s41598-023-37013-3>

Muralitharan, S., Nelson, W., Di, S., McGillion, M., Devereaux, P. J., Barr, N. G., & Petch, J. (2021). Machine learning–Based early warning systems for clinical deterioration: Systematic scoping review. *Journal of Medical Internet Research*, 23(2). <https://doi.org/10.2196/25187>

Nguyen, Q. H., Ly, H. B., Ho, L. S., Al-Ansari, N., Van Le, H., Tran, V. Q., Prakash, I., & Pham, B. T. (2021). Influence of data splitting on performance of machine learning models in prediction of shear strength of soil. *Mathematical Problems in Engineering*, 2021. <https://doi.org/10.1155/2021/4832864>

Peters, G. M., Peelen, R. V., Gilissen, V. J., Koning, M. V., van Harten, W. H., & Doggen, C. J. M. (2023). Detecting Patient Deterioration Early Using Continuous Heart rate and Respiratory rate Measurements in Hospitalized COVID-19 Patients. *Journal of Medical Systems*, 47(1). <https://doi.org/10.1007/s10916-022-01898-w>

Pranolo, A., Usha, F., & Khansa, A. (2024). *Enhanced Multivariate Time Series Analysis Using LSTM: A Comparative Study of Min-Max and Z-Score Normalization Techniques*. 16(2), 210–220.

Safiahani, N., Yunin, M., & Tan, T. L. (2025). *National Early Warning Score 2 (NEWS2) as a prognostic tool for adult patients in emergency department: A retrospective observational study*. 2, 1–16. <https://doi.org/10.1371/journal.pone.0326058>

Said, A. Ben, Erradi, A., Aly, H. A., & Mohamed, A. (2021). Predicting COVID-19 cases using bidirectional LSTM on multivariate time series. *Environmental Science and Pollution Research*, 28(40), 56043–56052. <https://doi.org/10.1007/s11356-021-14286-7>

Salhi, R. A., Greenwood-Ericksen, M., & Kocher, K. E. (2023). National Trends in Vital Sign Abnormalities at Arrival to the Emergency Department. *Western Journal of Emergency Medicine*, 24(3), 401–404. <https://doi.org/10.5811/westjem.58990>

Schwier, C. P. (2023). *The Evaluation of Pre-Extubation Vital Signs as Indicators for Extubation Failure in ICU Patients Objective: Results* : 1–13.

Shihab, M. Q. (2002). *M. Quraish Shihab*.

Su, C. F., Chiu, S. I., Jang, J. S. R., & Lai, F. (2022). Improved inpatient deterioration detection in general wards by using time-series vital signs.

Scientific Reports, 12(1), 1–11. <https://doi.org/10.1038/s41598-022-16195-2>

- Sundrani, S., Chen, J., Jin, B. T., Abad, Z. S. H., Rajpurkar, P., & Kim, D. (2023). Predicting patient decompensation from continuous physiologic monitoring in the emergency department. *Npj Digital Medicine*, 6(1), 1–10. <https://doi.org/10.1038/s41746-023-00803-0>
- Tofttrup, M., Sørensen, S. A., Ciosici, M. R., & Assent, I. (2021). A reproduction of Apple's bi-directional LSTM models for language identification in short strings. *EACL 2021 - 16th Conference of the European Chapter of the Association for Computational Linguistics, Proceedings of the Student Research Workshop*, 36–42. <https://doi.org/10.18653/v1/2021.eacl-srw.6>
- Xiang, J., Qiu, Z., Hao, Q., & Cao, H. (2020). Multi-time scale wind speed prediction based on WT-bi-LSTM. *MATEC Web of Conferences*, 309, 05011. <https://doi.org/10.1051/mateconf/202030905011>
- Xie, J., Wang, Z., Yu, Z., & Guo, B. (2022). Enabling Timely Medical Intervention by Exploring Health-Related Multivariate Time Series with a Hybrid Attentive Model. *Sensors*, 22(16). <https://doi.org/10.3390/s22166104>
- Yang, Z., Jia, R., Wang, P., Yao, L., & Shen, B. (2023). Supervised Attention-Based Bidirectional Long Short-Term Memory Network for Nonlinear Dynamic Soft Sensor Application. *ACS Omega*, 8(4), 4196–4208. <https://doi.org/10.1021/acsomega.2c07400>

LAMPIRAN

LAMPIRAN 1 TABEL DATA SEBELUM TRANSFORMASI DAN PERHITUNGAN ATRIBUT

<i>Patient_id</i>	<i>Day</i>	<i>HR</i>	<i>RR</i>	<i>SpO₂</i>	<i>Systolic</i>	<i>Diastolic</i>	<i>Temp</i>	<i>MAP</i>	<i>Jam</i>	<i>Menit</i>	<i>Detik</i>
1	1	0.000000	0.000000	0.191098	0.30	1.000000	0.647787	1.000000	21	49	46
1	2	0.076923	1.000000	0.464456	0.40	0.857143	0.000000	0.941176	21	50	46
1	3	0.076923	0.500000	0.968016	0.65	0.428571	1.000000	0.735294	21	51	46
1	4	1.000000	0.666667	0.000000	0.00	0.000000	0.264823	0.000000	21	52	46
1	5	0.230769	0.666667	1.000000	1.00	0.285714	0.857608	0.823529	21	53	46

LAMPIRAN 2 TABEL DATA SETELAH TRANSFORMASI DAN PERHITUNGAN ATRIBUT

<i>patient_id</i>	<i>day</i>	X'_{2j}	X'_{3j}	X'_{4j}	X'_{5j}	X'_{6j}	X'_{7j}	X'_{8j}	<i>Jam</i>	<i>Menit</i>	<i>Detik</i>	Z_{2j}	Z_{3j}	Z_{4j}	<i>R</i>	<i>T</i>
1	1	0.000 000	0.00000 0	0.19109 8	0.3 0	1.00000 0	0.647 787	1.000 000	21	49	46	-	-	-	91.3	-
1	2	0.076 923	1.00000 0	0.46445 6	0.4 0	0.85714 3	0.000 000	0.941 176	21	50	46	+2	-1	+2	93.3	+0.1
1	3	0.076 923	0.50000 0	0.96801 6	0.6 5	0.42857 1	1.000 000	0.735 294	21	51	46	+2	+1	-1	92.3	0.0
1	4	1.000 000	0.66666 7	0.00000 0	0.0 0	0.00000 0	0.264 823	0.000 000	21	52	46	+3	+1	-1	94.3	+0.1

<i>patient_id</i>	<i>day</i>	X'_{2j}	X'_{3j}	X'_{4j}	X'_{5j}	X'_{6j}	X'_{7j}	X'_{8j}	Jam	Menit	Detik	Z_{2j}	Z_{3j}	Z_{4j}	<i>R</i>	<i>T</i>
1	5	0.230 769	0.66666 7	1.00000 0	1.0 0	0.28571 4	0.857 608	0.823 529	21	53	46	+2	-1	+1	95.3	0.0

LAMPIRAN 3 PERHITUNGAN *FORGET GATE FORWARD*

$$f_t^{forward} = \sigma(W_f^{forward} \cdot [h_{j-1}^{forward}, Q_t] + b_f^{forward}) \quad (3.5)$$

- Data latih pada baris pertama (Q_t) = [0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]
- Nilai *hidden state* h_{j-1} = [0.5, 0.5, 0.5]
- Gabungan vektor $[h_{j-1}, Q_t]$ = [0.5, 0.5, 0.5, 0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]
- Nilai matrix bobot $W_f^{forward}$ (jumlah neuron x panjang $[h_{j-1}, Q_t]$):

$$W_f^{forward} = \begin{bmatrix} 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 \\ 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 & 0.4 \\ 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 & 0.4 & 0.6 \end{bmatrix}$$

- Nilai bias b_f = 0.1

Baris	Perhitungan Tiap Baris	Hasil	Perhitungan Sigmoid	Hasil
1	$(0.2 \times 0.5) + (0.3 \times 0.5) + (0.4 \times 0.5) + \dots + (0.2 \times 0.9412) + 0.1$	2.365	$\sigma(2.365) = \frac{1}{1 + e^{-2.365}}$	0.91
2	$(0.3 \times 0.5) + (0.4 \times 0.5) + (0.5 \times 0.5) + \dots + (0.4 \times 0.9412) + 0.1$	2.611	$\sigma(2.611) = \frac{1}{1 + e^{-2.611}}$	0.93
3	$(0.4 \times 0.5) + (0.5 \times 0.5) + (0.6 \times 0.5) + \dots + (0.6 \times 0.9412) + 0.1$	2.746	$\sigma(2.746) = \frac{1}{1 + e^{-2.746}}$	0.94

$$W_f^{forward} = [0.91, 0.93, 0.94]$$

LAMPIRAN 4 PERHITUNGAN *FORGET GATE BACKWARD*

$$f_t^{backward} = \sigma(W_f^{backward} \cdot [h_{j-1}^{backward}, Q_t] + b_f^{backward}) \quad (3.6)$$

- Data latih pada baris pertama (Q_t) = [0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]
- *Hidden state* berikutnya (h_{j+1}) = [0.5, 0.5, 0.5]
- Gabungan vektor $[h_{j+1}, Q_t]$ = [0.5, 0.5, 0.5, 0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]

- Matriks bobot *backward* ($W_f^{backward}$):

$$W_f^{backward} = \begin{bmatrix} 0.1 & 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 \\ 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 & 0.3 \\ 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 & 0.3 & 0.5 \end{bmatrix}$$

- Nilai bias $b_f^{backward} = 0.1$

Baris	Perhitungan Tiap Baris	Hasil	Perhitungan Sigmoid	Hasil
1	$(0.1 \times 0.5) + (0.2 \times 0.5) + (0.3 \times 0.5) + \dots + (0.1 \times 0.9412) + 0.1$	1.841	$\sigma(1.841) = \frac{1}{1 + e^{-1.841}}$	0.86
2	$(0.2 \times 0.5) + (0.3 \times 0.5) + (0.4 \times 0.5) + \dots + (0.3 \times 0.9412) + 0.1$	2.087	$\sigma(2.087) = \frac{1}{1 + e^{-2.087}}$	0.89
3	$(0.3 \times 0.5) + (0.4 \times 0.5) + (0.5 \times 0.5) + \dots + (0.5 \times 0.9412) + 0.1$	2.222	$\sigma(2.222) = \frac{1}{1 + e^{-2.222}}$	0.90

$$W_f^{backward} = [0.86, 0.89, 0.90]$$

LAMPIRAN 5 PERHITUNGAN *INPUT GATE FORWARD*

$$i_t^{forward} = \sigma(W_i^{forward} \cdot [h_{j-1}^{forward}, Q_t] + b_i^{forward}) \quad (3.7)$$

- Data latih pada baris pertama (Q_t) = [0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]
- Nilai *hidden state* h_{j-1} = [0.5, 0.5, 0.5]
- Gabungan vektor $[h_j - 1, Q_t] = [0.5, 0.5, 0.5, 0.0769, 1.0, 0.464, 0.4, 0.857, 0.0, 0.941]$
- Nilai matrix bobot $W_i = (\text{jumlah neuron}) + (\text{panjang } [h_{j-1}, Q_t])$

$$W_i^{forward} = \begin{bmatrix} 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 \\ 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 & 0.4 \\ 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 & 0.4 & 0.6 \end{bmatrix}$$

- Nilai bias $b_i^{forward} = 0.1$

Baris	Perhitungan Tiap Baris	Hasil	Perhitungan Sigmoid	Hasil
1	$(0.2 \times 0.5) + (0.3 \times 0.5) + (0.4 \times 0.5) + \dots + (0.2 \times 0.9412) + 0.1$	2.3647	$\sigma(2.3647) = \frac{1}{1 + e^{-2.3647}}$	0.91
2	$(0.3 \times 0.5) + (0.4 \times 0.5) + (0.5 \times 0.5) + \dots + (0.4 \times 0.9412) + 0.1$	2.6114	$\sigma(2.6114) = \frac{1}{1 + e^{-2.6114}}$	0.93
3	$(0.4 \times 0.5) + (0.5 \times 0.5) + (0.6 \times 0.5) + \dots + (0.6 \times 0.9412) + 0.1$	2.7458	$\sigma(2.7458) = \frac{1}{1 + e^{-2.7458}}$	0.94

$$i_t^{forward} = [0.91, 0.93, 0.94]$$

LAMPIRAN 6 PERHITUNGAN *INPUT GATE BACKWARD*

$$i_t^{backward} = \sigma(W_t^{backward} \cdot [h_{j+1}^{backward}, x_t] + b_t^{backward}) \quad (3.7)$$

- Data latih pada baris pertama (j_i) = [0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0, 0.9412]
- Nilai hidden state $h_{j+1} = [0.5, 0.5]$
- Gabungan vektor $[h_j + 1, Q_t] = [0.5, 0.5, 0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0, 0.9412]$
- Nilai matriks bobot W_t (jumlah neuron) dan panjang $[h_{j+1}, Q_t]$:

$$W_i^{backward} = \begin{bmatrix} 0.1 & 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 \\ 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 & 0.3 \\ 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 & 0.3 & 0.5 \end{bmatrix}$$

- Nilai bias $b_i = 0.1$

Baris	Perhitungan Tiap Baris	Hasil	Perhitungan Sigmoid	Hasil
1	$(0.1 \times 0.5) + (0.2 \times 0.5) + (0.3 \times 0.5) + \dots + (0.9 \times 0.9412) + 0.1$	1.8407	$\sigma(1.8407) = \frac{1}{1 + e^{-1.8407}}$	0.8630
2	$(0.2 \times 0.5) + (0.3 \times 0.5) + (0.4 \times 0.5) + \dots + (0.3 \times 0.9412) + 0.1$	2.0874	$\sigma(2.0874) = \frac{1}{1 + e^{-2.0874}}$	0.8897
3	$(0.3 \times 0.5) + (0.4 \times 0.5) + (0.5 \times 0.5) + \dots + (0.5 \times 0.9412) + 0.1$	2.2218	$\sigma(2.2218) = \frac{1}{1 + e^{-2.2218}}$	0.9022

$$i_t^{backward} = [0.8630, 0.8897, 0.9022]$$

LAMPIRAN 7 PERHITUNGAN KANDIDAT *CELL STATE FORWARD*

$$\bar{C}_t^{forward} = \tanh(W_c^{forward} \cdot [h_{t-1}^{forward}, x_t] + b_c^{forward}) \quad (3.8)$$

- Data latih pada baris pertama (x_t) [0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]
- Nilai *hidden state* $h_t - 1 = [0.5, 0.5, 0.5]$
- Gabungan vektor $[h_t - 1, x_t] = [0.5, 0.5, 0.5, 0.0769, 1.0, 0.4645, 0.4, 0.8571, 0.0, 0.9412]$
- Matriks bobot $W_c = (\text{jumlah neuron}) + (\text{panjang } [h_{j-1}, Q_t])$

$$W_c^{forward} = \begin{bmatrix} 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 \\ 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 & 0.4 \\ 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 & 0.4 & 0.6 \end{bmatrix}$$

- Nilai bias $b_c = 0.1$

Baris	Perhitungan Tiap Baris	Hasil	Perhitungan Sigmoid	Hasil
1	$(0.2 \times 0.5) + (0.3 \times 0.5) + (0.4 \times 0.5) + \dots + (0.2 \times 0.9412) + 0.1$	2.365	$\tanh(2.365) = \frac{e^{2.365} - e^{-2.365}}{e^{2.365} + e^{-2.365}}$	0.98
2	$(0.3 \times 0.5) + (0.4 \times 0.5) + (0.5 \times 0.5) + \dots + (0.4 \times 0.9412) + 0.1$	2.611	$\tanh(2.611) = \frac{e^{2.611} - e^{-2.611}}{e^{2.611} + e^{-2.611}}$	0.99
3	$(0.4 \times 0.5) + (0.5 \times 0.5) + (0.6 \times 0.5) + \dots + (0.6 \times 0.9412) + 0.1$	2.746	$\tanh(2.746) = \frac{e^{2.746} - e^{-2.746}}{e^{2.746} + e^{-2.746}}$	0.99

$$\bar{C}_t^{forward} = [0.98, 0.99, 0.99]$$

LAMPIRAN 8 PERHITUNGAN KANDIDAT *CELL STATE BACKWARD*

$$\bar{C}_t^{backward} = \tanh(W_c^{backward} \cdot [h_{j+1}^{backward}, Q_t] + b_c^{backward}) \quad (3.9)$$

- Data latih pada baris pertama (x_t) = [0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]
- Nilai *hidden state* $h_{j+1} = [0.5, 0.5, 0.5]$
- Gabungan vektor $[h_{j+1}, Q_t] = [0.5, 0.5, 0.5, 0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]$

- Nilai matriks bobot $W_c = (\text{jumlah neuron}) + (\text{panjang } [h_{j+1}, Q_t])$

$$W_c^{backward} = \begin{bmatrix} 0.1 & 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 \\ 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 & 0.3 \\ 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 & 0.3 & 0.5 \end{bmatrix}$$

- Nilai bias $b_c = 0.1$

Baris	Perhitungan Tiap Baris	Hasil	Perhitungan Sigmoid	Hasil
1	$(0.1 \times 0.5) + (0.2 \times 0.5) + (0.3 \times 0.5) + \dots + (0.1 \times 0.9412) + 0.1$	1.841	$\tanh(1.841) = \frac{e^{1.841} - e^{-1.841}}{e^{1.841} + e^{-1.841}}$	0.95
2	$(0.2 \times 0.5) + (0.3 \times 0.5) + (0.4 \times 0.5) + \dots + (0.3 \times 0.9412) + 0.1$	2.087	$\tanh(2.087) = \frac{e^{2.087} - e^{-2.087}}{e^{2.087} + e^{-2.087}}$	0.97
3	$(0.3 \times 0.5) + (0.4 \times 0.5) + (0.5 \times 0.5) + \dots + (0.5 \times 0.9412) + 0.1$	2.222	$\tanh(2.222) = \frac{e^{2.222} - e^{-2.222}}{e^{2.222} + e^{-2.222}}$	0.98

$$\bar{C}_t^{backward} = [0.95, 0.97, 0.98]$$

LAMPIRAN 9 PERHITUNGAN PEMBARUAN CELL STATE *FORWARD*

$$C_t^{forward} = f_t^{forward} \cdot C_{j-1}^{forward} + i_t^{forward} \cdot \bar{C}_t^{forward} \quad (3.10)$$

- Nilai $f_t^{forward} = [0.9141, 0.9316, 0.9397]$
- Nilai $i_t^{forward} = [0.9141, 0.9316, 0.9397]$
- Nilai $\bar{C}_t^{forward} = [0.9825, 0.9893, 0.9918]$
- Nilai $C_{j-1}^{forward} = [0, 0, 0]$

Baris	Perhitungan tiap baris	Hasil
1	$(0.9141 \times 0) + (0.9141 \times 0.9825)$	0.8983
2	$(0.9316 \times 0) + (0.9316 \times 0.9893)$	0.9215
3	$(0.9397 \times 0) + (0.9397 \times 0.9918)$	0.9322

$$C_t^{forward} = [0.8983, 0.9215, 0.9322]$$

LAMPIRAN 10 PERHITUNGAN PEMBARUAN CELL STATE *BACKWARD*

$$C_t^{backward} = f_t^{backward} \cdot C_{j+1}^{backward} + i_t^{backward} \cdot \bar{C}_t^{backward} \quad (3.11)$$

- Nilai $f_t^{backward} = [0.8630, 0.8897, 0.9022]$
- Nilai $i_t^{backward} = [0.8630, 0.8897, 0.9022]$
- Nilai $\bar{C}_t^{backward} = [0.9509, 0.9697, 0.9768]$
- Nilai $C_{j+1}^{backward} = [0, 0, 0]$

Baris	Perhitungan tiap baris	Hasil
1	$(0.8630 \times 0) + (0.8630 \times 0.9509)$	0.8206
2	$(0.8897 \times 0) + (0.8897 \times 0.9697)$	0.8626
3	$(0.9022 \times 0) + (0.9022 \times 0.9768)$	0.8813

$$C_t^{backward} = [0.8206, 0.8626, 0.8813]$$

LAMPIRAN 11 PERHITUNGAN OUTPUT GATE *FORWARD*

$$O_t^{forward} = \sigma(W_o^{forward} [h_{j-1}^{forward}, x_t] + b_o^{forward}) \quad (3.12)$$

- Data latih pada baris pertama (Q_t) = $[0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]$
- Nilai *hidden state* $h_{j-1} = [0.5, 0.5, 0.5]$
- Gabungan vektor $[h_{j-1}, Q_t] = [0.5, 0.5, 0.5, 0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]$
- Nilai matriks bobot W_o =(jumlah neuron) + (panjang $[h_{j-1}, Q_t]$)

$$W_o^{forward} = \begin{bmatrix} 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 \\ 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 & 0.4 \\ 0.4 & 0.5 & 0.6 & 0.7 & 0.8 & 0.4 & 0.3 & 0.2 & 0.4 & 0.6 \end{bmatrix}$$

- Nilai bias $b_o = 0.1$

Baris	Perhitungan Tiap Baris	Hasil	Perhitungan Sigmoid	Hasil
1	$(0.2 \times 0.5) + (0.3 \times 0.5) + (0.4 \times 0.5) + \dots + (0.2 \times 0.9412) + 0.1$	2.3647	$\sigma(2.3647) = \frac{1}{1 + e^{-2.3647}}$	0.9141
2	$(0.3 \times 0.5) + (0.4 \times 0.5) + (0.5 \times 0.5) + \dots + (0.4 \times 0.9412) + 0.1$	2.6114	$\sigma(2.6114) = \frac{1}{1 + e^{-2.614}}$	0.9316
3	$(0.4 \times 0.5) + (0.5 \times 0.5) + (0.6 \times 0.5) + \dots + (0.6 \times 0.9412) + 0.1$	2.7458	$\sigma(2.7458) = \frac{1}{1 + e^{-2.7458}}$	0.9397

$$O_t^{forward} = [0.9141, 0.9316, 0.9397]$$

LAMPIRAN 12 PERHITUNGAN OUTPUT GATE *BACKWARD*

$$O_t^{backward} = \sigma(W_o^{backward}[h_{j-1}^{backward}, x_t] + b_o^{backward}) \quad (3.13)$$

- Data latih pada baris pertama (Q_t) = [0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]
- Nilai *hidden state* h_{j+1} = [0.5, 0.5, 0.5]
- Gabungan vektor $[h_{j+1}, Q_t] = [0.5, 0.5, 0.5, 0.0769, 1.0000, 0.4645, 0.4, 0.8571, 0.0000, 0.9412]$
- Nilai matriks bobot W_o =(jumlah neuron) + (panjang $[h_{j+1}, Q_t]$)

$$W_o^{backward} = \begin{bmatrix} 0.1 & 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 \\ 0.2 & 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 & 0.3 \\ 0.3 & 0.4 & 0.5 & 0.6 & 0.7 & 0.3 & 0.2 & 0.1 & 0.3 & 0.5 \end{bmatrix}$$

Baris	Perhitungan Tiap Baris	Hasil	Perhitungan Sigmoid	Hasil
1	$(0.1 \times 0.5) + (0.2 \times 0.5) + (0.3 \times 0.5) + \dots + (0.1 \times 0.9412) + 0.1$	1.8407	$\sigma(1.8407) = \frac{1}{1 + e^{-1.8407}}$	0.8630
2	$(0.2 \times 0.5) + (0.3 \times 0.5) + (0.4 \times 0.5) + \dots + (0.3 \times 0.9412) + 0.1$	2.0874	$\sigma(2.0874) = \frac{1}{1 + e^{-2.0874}}$	0.8897
3	$(0.3 \times 0.5) + (0.4 \times 0.5) + (0.5 \times 0.5) + \dots + (0.5 \times 0.9412) + 0.1$	2.2218	$\sigma(2.2218) = \frac{1}{1 + e^{-2.2218}}$	0.9022

$$O_t^{backward} = [0.8630, 0.8897, 0.9022]$$

LAMPIRAN 13 PERHITUNGAN OUTPUT TIMESTEP *FORWARD*

$$h_t^{forward} = O_t^{forward} \cdot \tanh(C_t^{forward}) \quad (3.13)$$

- Nilai $O_t^{forward} = [0.9141, 0.9316, 0.9397]$
- Nilai $C_t^{forward} = [0.8983, 0.9215, 0.9322]$

Baris	$O_t^{forward}$	$C_t^{forward}$	$\tanh(C_t^{forward})$	Hasil $h_t^{forward}$
1	0.9141	0.8983	$\tanh(0.8983) \approx 0.7156$	$0.9141 \cdot 0.7156 \approx 0.6542$
2	0.9316	0.9215	$\tanh(0.9215) \approx 0.7268$	$0.9316 \cdot 0.7268 \approx 0.6772$
3	0.9397	0.9322	$\tanh(0.9322) \approx 0.7329$	$0.9397 \cdot 0.7329 \approx 0.6888$

$$h_t^{forward} = [0.6542, 0.6772, 0.6888]$$

LAMPIRAN 14 PERHITUNGAN *OUTPUT TIMESTEP BACKWARD*

$$h_t^{backward} = O_t^{backward} \cdot \tanh(C_t^{backward}) \quad (3.13)$$

- Nilai $O_t^{backward} = [0.8630, 0.8897, 0.9022]$

- Nilai $c_t^{backward} = [0.8206, 0.8626, 0.8813]$

Baris	$O_t^{forward}$	$C_t^{forward}$	$\tanh (C_t^{forward})$	Hasil $h_t^{backward}$
1	0.8630	0.8206	$\tanh (0.8206) \approx 0.6770$	$0.8630 \cdot 0.6770 \approx 0.05842$
2	0.8897	0.8626	$\tanh (0.8626) \approx 0.6922$	$0.9316 \cdot 0.6992 \approx 0.6220$
3	0.9022	0.8813	$\tanh (0.8813) \approx 0.7082$	$0.9397 \cdot 0.7082 \approx 0.6390$

$$h_t^{backward} = [0.5842, 0.6220, 0.6390]$$