

Analisis Tantangan dan Performa Algoritma Deep Learning Dalam Prediksi Readmisi Pasien: Tinjauan Literatur Sistematis

Miftahus Surur^{*1}, Imam Tahyudin², Dhanar Intan Surya Saputra³, Agi Nanjar⁴

^{1,2,3,4}Magister Ilmu Komputer, Universitas Amikom Purwokerto, Indonesia

Email: 123MA41D026@students.amikompurwokerto.ac.id,

imam.tahyudin@amikompurwokerto.ac.id, dhanarsaputra@amikompurwokerto.ac.id,

kipli176@gmail.com

Abstrak

Readmisi pasien menjadi indikator utama kualitas layanan kesehatan dan memiliki dampak signifikan terhadap biaya medis. Prediksi yang akurat terhadap readmisi pasien dapat membantu penyedia layanan kesehatan dalam meningkatkan kualitas layanan kesehatan dan merancang strategi intervensi yang lebih efektif. Penelitian ini bertujuan untuk mengevaluasi algoritma deep learning dalam prediksi readmisi pasien, membandingkan kinerjanya dengan metode lain, serta mengidentifikasi tantangan dan peluang implementasi dalam sistem kesehatan. Studi ini merupakan tinjauan sistematis terhadap algoritma deep learning dengan menganalisis 30 artikel dari database utama seperti Scopus, IEEE Xplore, dan ScienceDirect. Proses pencarian literatur dilakukan menggunakan kombinasi kata kunci seperti 'deep learning', 'readmisi pasien', dan 'prediksi kesehatan' serta mengikuti kerangka PRISMA untuk menyaring studi yang relevan berdasarkan kriteria inklusi dan eksklusi. Hasil analisis menunjukkan bahwa algoritma *Long Short-Term Memory* (LSTM) memiliki performa terbaik dalam menangkap pola temporal dari data *Electronic Health Record* (EHR), dengan *Area Under the Curve* (AUC) mencapai 88,4%. Selain itu, *Convolutional Neural Networks* (CNN) terbukti efektif untuk menganalisis teks tidak terstruktur, sementara model *Transformer* menunjukkan potensi dalam menangani dataset berskala besar. Tantangan utama yang ditemukan meliputi ketidakseimbangan data dan heterogenitas data medis, yang dapat mempengaruhi akurasi prediksi. Solusi inovatif seperti federated learning dan *Explainable AI* (XAI) dapat meningkatkan interpretabilitas dan efisiensi model dalam konteks klinis. Penelitian ini memberikan wawasan berharga mengenai potensi deep learning dalam prediksi readmisi pasien serta menawarkan rekomendasi strategis untuk pengembangan teknologi kesehatan yang lebih baik.

Kata kunci: Deep Learning, Explainable AI, Federated Learning, LSTM, Prediksi Kesehatan, Readmisi Pasien.

Challenges and Performance Analysis of Deep Learning Algorithms In Patient Readmission Prediction: A Systematic Literature Review

Abstract

Readmissions are a key indicator of healthcare quality and have a significant impact on medical costs. Accurate prediction of patient readmissions can help healthcare providers improve healthcare quality and design more effective intervention strategies. This study aims to evaluate deep learning algorithms in patient readmission prediction, compare their performance with other methods, and identify implementation challenges and opportunities in the healthcare system. This study is a systematic review of deep learning algorithms by analyzing 30 articles from major databases such as Scopus, IEEE Xplore, and ScienceDirect. The literature search process was conducted using a combination of keywords such as 'deep learning', 'patient readmission', and 'health prediction' and followed the PRISMA framework to filter relevant studies based on inclusion and exclusion criteria. The analysis showed that the Long Short-Term Memory (LSTM) algorithm performed best in capturing temporal patterns from Electronic Health Record (EHR) data, with an Area Under the Curve (AUC) of 88.4%. In addition, Convolutional Neural Networks (CNN) proved effective for analyzing unstructured text, while the Transformer model showed potential in handling large-scale datasets. Key challenges found include data imbalance and heterogeneity of medical data, which can affect prediction accuracy. Innovative solutions such as federated learning and Explainable AI (XAI) can improve the interpretability and efficiency of models in

a clinical context. This research provides valuable insights into the potential of deep learning in patient readmission prediction and offers strategic recommendations for the development of better health technologies.

Keywords: Deep Learning, Explainable AI, Federated Learning, Health Prediction, LSTM, Patient Readmission.

1. PENDAHULUAN

Readmisi pasien, yang didefinisikan sebagai kunjungan kembali ke rumah sakit dalam waktu tertentu setelah keluar, menjadi indikator utama kualitas layanan kesehatan. Tingginya tingkat readmisi berkontribusi pada meningkatnya beban ekonomi dan sumber daya rumah sakit. Di Amerika Serikat, laporan dari Centers for Medicare & Medicaid Services [1] menunjukkan bahwa tingkat readmisi 30 hari mencapai sekitar 17.5%, menghasilkan beban ekonomi tambahan sebesar \$26 miliar per tahun. Di Indonesia, data dari Kementerian Kesehatan [2] menunjukkan bahwa readmisi pasien penyakit kronis, seperti diabetes dan gagal jantung, menyumbang lebih dari 20% pengeluaran rumah sakit. Tingginya angka ini menandakan perlunya pendekatan yang lebih efektif untuk memprediksi dan mengelola risiko readmisi.

Prediksi readmisi pasien merupakan tantangan utama dalam bidang kesehatan. Metode konvensional, seperti regresi logistic dan random forest, sering digunakan dalam analisis risiko readmisi. Namun, metode ini memiliki keterbatasan dalam menangkap pola kompleks dari data rekam medis elektronik (Electronic Health Records/EHR) yang bersifat temporal dan heterogen. Salah satu tantangan utama dalam penerapan deep learning adalah ketidakseimbangan data, yang dapat mengurangi akurasi model [3] menunjukkan bahwa pembelajaran untuk data medis yang tidak seimbang dapat ditingkatkan dengan strategi augmentation dan adversarial learning. Sebagai contoh, regresi logistik sering kali mengasumsikan hubungan linear antara variabel, sementara data medis sering kali memiliki interaksi non-linear yang signifikan [4]. Keterbatasan ini menimbulkan kebutuhan akan pendekatan yang lebih adaptif dan akurat.

Seiring berkembangnya kecerdasan buatan, Deep learning muncul sebagai solusi yang menjanjikan untuk mengatasi tantangan tersebut. Algoritma seperti Long Short-Term Memory (LSTM) dirancang khusus untuk menangani data sekuensial dengan pola temporal, sebagaimana dibuktikan dalam penelitian [5], yang menunjukkan bahwa model LSTM mencapai Area Under the Curve (AUC) sebesar 88.4%, jauh melampaui performa metode tradisional. Selain itu, Convolutional Neural Networks (CNN) unggul dalam analisis teks tidak terstruktur dari catatan medis, dengan akurasi hingga 75.6% sebagaimana ditunjukkan dalam studi[4]. Model berbasis Transformer, yang semakin populer dalam analisis dataset besar dan kompleks, juga mulai diadopsi dalam prediksi readmisi pasien. Studi dalam [6] menunjukkan bahwa Transformer mampu menangani klaim asuransi elektronik secara efisien dengan integrasi data multimodal. Dengan keunggulan ini, deep learning menawarkan potensi untuk meningkatkan akurasi prediksi, efisiensi, dan interpretabilitas model dalam konteks klinis. Selain itu, penelitian dalam [7] menunjukkan bahwa pendekatan Explainable AI (XAI) dalam pemrosesan bahasa alami (NLP) untuk healthcare telah berhasil meningkatkan transparansi model deep learning

Namun, implementasi deep learning dalam prediksi readmisi masih menghadapi berbagai tantangan, termasuk ketidakseimbangan data, heterogenitas rekam medis, interpretabilitas model, serta aspek privasi dan keamanan data pasien. Studi dalam [8] menyoroti bahwa keterbatasan interpretabilitas model deep learning dalam healthcare dapat diatasi dengan kombinasi model Explainable AI dan hybrid learning framework. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi algoritma deep learning dalam prediksi readmisi pasien, membandingkan performa berbagai metode berdasarkan metrik evaluasi seperti AUC dan F1-score, mengidentifikasi tantangan utama serta solusi potensial, termasuk penerapan Explainable AI (XAI) dan federated learning untuk meningkatkan interpretabilitas dan keamanan model. Studi dalam [9] menunjukkan bahwa federated learning dapat diterapkan dalam sistem kesehatan berbasis cloud untuk memungkinkan model deep learning dilatih tanpa berbagi data mentah antar rumah sakit, sehingga meningkatkan keamanan dan privasi pasien. Kajian ini diharapkan dapat memberikan wawasan mendalam bagi peneliti dan praktisi kesehatan dalam mengembangkan sistem prediksi readmisi berbasis deep learning yang lebih akurat, aman, dan dapat diterapkan dalam skala klinis.

2. METODE PENELITIAN

Penelitian ini dilakukan dengan pendekatan Tinjauan Literatur Sistematis (Systematic Literature Review/SLR) untuk mengidentifikasi, mengevaluasi, dan merangkum penelitian yang membahas penggunaan

deep learning dalam prediksi readmisi pasien. Metode ini menggunakan kerangka kerja PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) sebagaimana diperbarui dalam studi [10]. PRISMA 2020 memberikan panduan sistematis untuk melakukan tinjauan literatur, memastikan bahwa proses seleksi artikel dilakukan secara transparan, terstruktur, dan dapat direplikasi. Pendekatan multimodal juga semakin banyak diterapkan dalam penelitian prediksi readmisi pasien untuk menggabungkan berbagai jenis data klinis [11]. Studi dalam [11] menunjukkan bahwa kombinasi data structured dan unstructured dalam deep learning dapat meningkatkan akurasi prediksi dalam healthcare.

Penggunaan PRISMA membantu memastikan bahwa literatur yang dipilih memiliki kualitas tinggi dan relevansi yang kuat dengan tujuan penelitian, memungkinkan hasil penelitian yang lebih valid dan dapat dipercaya. Proses ini juga mendukung pelaporan yang sistematis dan konsisten, sehingga dapat memberikan kontribusi yang signifikan pada literatur di bidang prediksi readmisi pasien.

2.1. Research Questions

Penelitian ini dirancang untuk menjawab tiga pertanyaan utama (Research Questions, RQ) yang berfokus pada penerapan deep learning dalam prediksi readmisi pasien.

- **RQ1:** Algoritma deep learning apa saja yang digunakan dalam prediksi readmisi pasien pada literatur terkini?
- **RQ2:** Bagaimana performa algoritma deep learning dalam memprediksi readmisi pasien berdasarkan metrik evaluasi seperti AUC dan F1-score?
- **RQ3:** Apa saja tantangan utama dan peluang pengembangan dalam penerapan deep learning untuk prediksi readmisi pasien?

Penelitian sebelumnya telah menunjukkan bahwa deep learning dapat digunakan untuk memprediksi early bounce-back readmission, yang menjadi faktor penting dalam perencanaan intervensi dini bagi pasien risiko tinggi [12].

2.2. Search Process

Penelusuran literatur dilakukan secara sistematis menggunakan tiga database utama, yaitu Scopus, IEEE Xplore, dan ScienceDirect. Strategi pencarian menggunakan kata kunci Boolean seperti ("deep learning" AND "hospital readmission") OR ("healthcare" AND "readmission prediction")" untuk Scopus, ("deep learning" OR "neural networks") AND ("readmission prediction" OR "healthcare analytics")" untuk ScienceDirect, dan ("deep learning" AND "readmission risk") OR ("neural networks" AND "patient readmission")" untuk IEEE Xplore.

Kata kunci ini dirancang untuk memastikan bahwa literatur yang diidentifikasi relevan dengan topik penelitian. Strategi pencarian menggunakan kata kunci Boolean yang menggabungkan istilah utama seperti "deep learning," "hospital readmission prediction," dan "healthcare". Pendekatan ini telah digunakan dalam penelitian [13], yang menganalisis jaringan komorbiditas penyakit untuk meningkatkan efektivitas model prediksi berbasis deep learning dalam sektor kesehatan. Proses ini dirancang untuk memastikan bahwa literatur yang diidentifikasi relevan dengan topik penelitian.

Rentang waktu penerbitan literatur difokuskan pada tahun 2019 hingga 2024, dengan tujuan menjaga relevansi terhadap teknologi dan pendekatan terkini dalam bidang prediksi readmisi pasien menggunakan deep learning. Penelitian terbaru menunjukkan bahwa tren penggunaan perangkat mobile dalam pemantauan kesehatan telah menjadi faktor penting dalam prediksi readmisi pasien, yang semakin banyak diteliti dalam literatur terbaru[14].

2.3. Inclusion and Exclusion Criteria

Penentuan kriteria inklusi dan eksklusi bertujuan untuk memastikan bahwa literatur yang dikaji relevan dan memiliki kualitas yang baik.

Tabel 1. Tabel Kriteria Inklusi dan Eksklusi

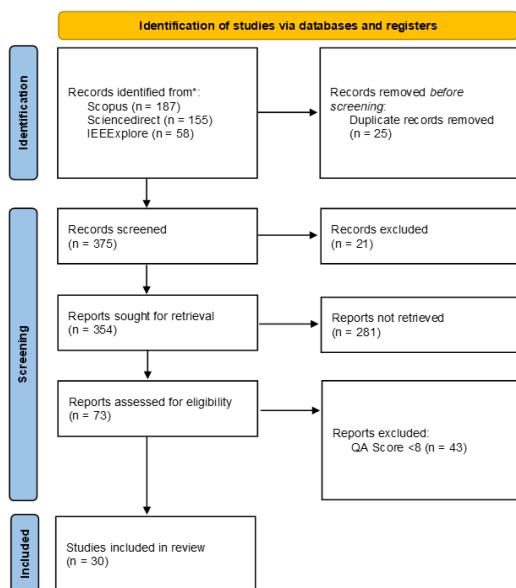
Kategori	Kata Kunci	Rentang Waktu
Jenis Publikasi	Artikel jurnal, konferensi ilmiah, atau buku akademik yang terindeks pada Scopus, IEEE Xplore, atau pada database yang disebutkan	Publikasi yang tidak terindeks pada database yang disebutkan

Bahasa	ScienceDirect	Publikasi dalam bahasa Inggris	Publikasi dalam bahasa lain
Rentang Waktu	Studi yang diterbitkan antara tahun 2019 dan 2024	Studi yang diterbitkan sebelum tahun 2019	
Relevansi	Penelitian yang menggunakan deep learning untuk prediksi readmisi pasien	Penelitian yang menggunakan metode selain deep learning	
Ketersediaan Dokumen	Dokumen dengan teks lengkap yang dapat diakses	Dokumen tanpa akses teks lengkap	

2.4. Proses Seleksi Literatur (PRISMA Flowchart)

Seleksi artikel dilakukan dalam beberapa tahap:

- Identifikasi: Mengumpulkan artikel dari database berdasarkan kata kunci yang telah ditentukan.
 - Screening: Menghapus duplikasi dan artikel yang tidak relevan berdasarkan judul dan abstrak.
 - Kelayakan: Membaca isi penuh artikel dan mengevaluasi kesesuaianya dengan kriteria inklusi eksklusi.
 - Analisis Akhir: Memilih artikel yang memenuhi semua kriteria dan menyusun sintesis penelitian.
- Proses seleksi artikel divisualisasikan pada Gambar 1.



Gambar 1. Diagram Prisma

2.5. Proses Quality Assessment

Quality assessment dilakukan untuk memastikan bahwa literatur yang dipilih memenuhi standar kualitas yang relevan dengan topik penelitian. Penilaian ini melibatkan evaluasi metodologi, validitas, reliabilitas hasil, dan relevansi studi terhadap tujuan penelitian. Artikel yang memenuhi kriteria minimal berdasarkan checklist/rubrik akan dilanjutkan untuk dianalisis.

Tabel 2. Tabel Checklist untuk Penilaian Kualitas

No	Pertanyaan Penilaian	Skor (0-2)
1	Apakah tujuan penelitian dijelaskan dengan jelas?	0: Tidak, 1: Parsial, 2: Ya
2	Apakah metodologi penelitian dijelaskan dengan detail, termasuk algoritma yang digunakan?	0: Tidak, 1: Parsial, 2: Ya
3	Apakah dataset yang digunakan untuk pelatihan dan pengujian model dijelaskan?	0: Tidak, 1: Parsial, 2: Ya
4	Apakah hasil evaluasi model dilaporkan dengan metrik yang jelas	0: Tidak, 1: Parsial, 2: Ya

		dan relevan?	
5		Apakah hasil penelitian dibandingkan dengan metode atau pendekatan lain?	0: Tidak, 1: Parsial, 2: Ya
6		Apakah terdapat diskusi tentang kekuatan, kelemahan, atau tantangan implementasi algoritma yang digunakan?	0: Tidak, 1: Parsial, 2: Ya
7		Apakah artikel memberikan kontribusi baru atau inovasi yang signifikan terhadap topik?	0: Tidak, 1: Parsial, 2: Ya

Skor Total: Artikel dengan skor ≥ 8 akan dianggap memenuhi standar kualitas untuk dianalisis lebih lanjut.

3. HASIL DAN PEMBAHASAN

Proses sistematis yang digunakan dalam penelitian ini memastikan bahwa hasil yang diperoleh berasal dari literatur dengan kualitas dan relevansi tinggi. Dengan menerapkan kriteria inklusi-eksklusi yang ketat, jumlah artikel yang awalnya sebanyak 400 berhasil disaring menjadi 30 artikel yang memenuhi standar kualitas, sesuai dengan checklist yang dirancang.

3.1. RQ1: Algoritma Deep Learning yang Paling Sering Digunakan

Dari hasil analisis 30 artikel yang telah dirangkum, ditemukan berbagai algoritma deep learning yang digunakan dalam prediksi readmisi pasien. Algoritma yang paling umum mencakup LSTM dan variannya (Bi-LSTM dan Time-Aware LSTM) untuk data sekuenzial, CNN untuk analisis teks medis, dan Autoencoders digunakan ekstraksi fitur dan reduksi dimensi data. Sementara model berbasis Transformer mulai banyak digunakan untuk dataset berskala besar yang membutuhkan pemrosesan paralel. Berikut adalah tabel 3 yang merangkum algoritma, dataset, metrik kinerja, serta tantangan dan peluang dari penelitian yang diulas:

Tabel 3. Tabel Checklist untuk Penilaian Kualitas

No	Algoritma	Dataset	Metrik Kinerja	Tantangan	Peluang	Studi
1	LSTM	EHR	F1 Score: 87.3%, AUC: 88.4%	Data Heterogen	Peningkatan deteksi pola temporal	[5]
2	Bi-LSTM	IBM MarketScen databases	AUC: 0.861(90 hari)	Ketidakseimbangan Data	Intervensi pasien beresiko tinggi	[15]
3	Time-Aware LSTM	EHR	AUC: 0.82	Ketidakseimbangan Data	Prediksi komplikasi akut	[16]
4	Semantic-Based Attention Model	EHR	Peningkatan Akurasi 5%	Representasi Semantik Kode	Peningkatan analitik prediktif	[17]
5	CNN	Catatan Klinis	Akurasi: 75.6%	Analisis Teks Tidak Terstruktur	Ekstraksi fitur efisien	[18]
6	BERTopic with LSTM	MIMIC-III	AUC: 0.80	Kompleksitas daata heterogen	interpretabilitas tanbahan	[19]
7	Vision Transformer(ViT)	Data Klaim Elektronik		Dimensi data tinggi	Analisis data bersekala besar	[20]
8	Autoencoders	EHR	Akurasi: 92.4%	Heterogenitas data	Ekstraksi fitur relevan	[21]
9	Cost-Sensitive Learning	EHR	Recall meningkat 26%	Kompleksitas Hubungan kode medis	Peningkatan performa pada minoritas data	[22]
10	Doc2Vec with Deep Learning	Catatan Klinis	AUROC: 0.766	Variabilitas data sensor	Peningkatan analisis teks medis	[12]
11	Multitasking LSTM	Sensor Fisik	Akurasi: 94.84%, RMSE: 0.077	Menggabungkan data heterogen	prediksi gabungan lama rawat inap dan readmisi	[23]

12	Hybrid LSTM-CNN	EHR dan Gambar	Akurasi: 85.7%	Kompleksitas spasial-temporal data	peningkatan akurasi dalam analisis gabungan	[24]
13	Generative Adversarial Networks(GANs)	EHR	Meningkatkan Representasi data minoritas	Mengintegrasikan pembelajaran berbasis aksi	Penggunaan data sintesis untuk pelatihan	[25]
14	LR,KNN,SVM, CNN,RNN	EHR	CNN = 92.4% (tanpa normalisasi), CNN (dengan normalisasi Z-Score) = 89.4%, ML terbaik (SVM) = 88.6%	Ketidakseimbangan data dan kompleksitas data	Penggunaan data preprocessing, kombinasi model dan feature engineer	[26]
15	CNN, random forest	MIMIC III	CNN memiliki F1-score 0.756, sedangkan Random Forest 0.674.	Data dari unit ICU	Penggunaan data bisa dari dataset yang lebih luas	[27]

Algoritma deep learning yang digunakan menunjukkan fleksibilitas tinggi dalam menangani data medis yang heterogen, temporal, dan sering kali tidak terstruktur. Pilihan algoritma biasanya bergantung pada karakteristik data dan tujuan spesifik penelitian. Contohnya, LSTM dan varian lainnya lebih cocok untuk data sekuensial seperti EHR, sementara CNN lebih sesuai untuk analisis teks atau gambar medis.

Hasil penelitian ini juga menyoroti pentingnya penggunaan model hybrid seperti kombinasi LSTM dengan mekanisme perhatian atau model berbasis transformer untuk meningkatkan akurasi prediksi. Sudi dalam [19] menemukan bahwa pendekatan BERTopic dengan LSTM dapat meningkatkan interpretabilitas model tanpa mengorbankan akurasi, menjadikannya lebih dapat diterapkan dalam lingkungan klinis. Misalnya, TADEL mengungguli model baseline dengan peningkatan AUC hingga 15%, menunjukkan keunggulan dalam menangkap pola temporal kompleks pada data EHR dibandingkan dengan model tradisional seperti Logistic Regression yang rata-rata mencapai AUC di bawah 75%, sementara kombinasi BERTopic dengan LSTM memberikan interpretabilitas tambahan tanpa mengorbankan akurasi.

Namun, tantangan seperti ketidakseimbangan data, interpretabilitas model, dan kebutuhan akan data granular masih menjadi kendala yang perlu diatasi dalam penelitian mendatang. Penelitian lanjutan dapat mengintegrasikan data klinis yang lebih terperinci serta menggunakan mekanisme perhatian untuk mengakomodasi dinamika temporal dalam data pasien.

Dari hasil ini, dapat disimpulkan bahwa inovasi dalam pengembangan algoritma, seperti integrasi mekanisme perhatian atau penggunaan model berbasis transformer, mampu meningkatkan performa prediksi dan membuka peluang untuk implementasi lebih luas dalam sistem kesehatan.

3.2. RQ2: Performa Algoritma Deep Learning dalam Memprediksi Readmisi Pasien Berdasarkan Metrik Evaluasi

Performa algoritma deep learning dalam memprediksi readmisi pasien bervariasi tergantung pada jenis algoritma, dataset, dan metrik evaluasi yang digunakan. Berikut adalah tabel 4 rangkuman performa berdasarkan penelitian yang diulas:

Tabel 4. Performa Algoritma Deep Learning

Algoritma	Evaluasi Metrik	Dataset	Performa	Studi
LSTM	F1 Score: 87.3%, AUC: 88.4%	EHR	Efektif dalam menangkap pola temporal Xie et al. (2021)	[5]
Bi-LSTM	AUC: 0.861 (90 hari)	IBM MarketScan databases	Mengungguli model tradisional	[15]

Time-Aware LSTM	AUC: 0.82	EHR	Menangani data temporal dengan interval waktu	[22]
CNN	Akurasi: 75.6%	Catatan klinis	Efektif dalam ekstraksi fitur dari data teks	[27]
BERTopic with LSTM	AUC: 0.80	MIMIC-III	Menyediakan interpretabilitas tambahan	[19]
Autoencoders	Akurasi: 92.4%	EHR	Efektif untuk pengurangan dimensi data	[21]
Multitasking LSTM	Akurasi: 94.84%, RMSE: 0.077	Sensor fisik	Prediksi gabungan lama rawat inap dan readmisi	[23]
Transformer-Based Models	AUC: 0.668	Data klaim elektronik	Efektif untuk data berskala besar dengan dimensi tinggi	[20]

Performa algoritma menunjukkan bahwa LSTM dan varian terkait seperti Bi-LSTM serta Time-Aware LSTM cenderung unggul dalam menangani data temporal dari EHR. Contohnya, studi dalam (2021) berdasarkan hasil evaluasi performa, LSTM mencapai AUC sebesar 88.4% dalam prediksi readmisi pasien menggunakan dataset EHR, menunjukkan kemampuannya dalam menangani pola temporal. Sebagai perbandingan, model tradisional seperti Logistic Regression yang memiliki AUC lebih rendah, sekitar 75%, menunjukkan keterbatasannya dalam menangkap kompleksitas data sekuensial. Selain itu, penelitian dalam (2021) memperkuat kemampuan menangkap interval waktu spesifik antara data, memberikan akurasi lebih tinggi untuk skenario temporal yang kompleks. Selain itu, penggunaan model hybrid seperti BERTopic dengan LSTM meningkatkan interpretabilitas tanpa mengorbankan akurasi, menjadikannya pilihan yang menarik untuk aplikasi klinis.

Model seperti autoencoders dan multitasking LSTM juga memberikan hasil yang sangat baik dalam kasus penggunaan spesifik, seperti pengurangan dimensi data dan analisis sensor fisik. Studi dalam [23] menunjukkan bahwa multitask deep learning yang menggabungkan prediksi lama tinggal pasien (Length of Stay) dan kemungkinan readmisi memiliki tingkat akurasi hingga 94.84%. Namun, metrik evaluasi seperti AUC dan F1 Score tetap menjadi indikator utama dalam mengevaluasi performa model.

3.3. RQ3: Tantangan Utama dan Peluang Pengembangan dalam Penerapan Deep Learning untuk Prediksi Readmisi Pasien

3.3.1. Tantangan Utama

Dalam pengembangan model deep learning untuk prediksi readmisi pasien, terdapat beberapa tantangan utama yang perlu diatasi. Pertama, ketidakseimbangan data menjadi masalah signifikan karena banyak dataset medis memiliki proporsi kelas yang tidak seimbang, seperti jumlah pasien yang readmisi dibandingkan dengan yang tidak. Ketidakseimbangan ini dapat memengaruhi performa model dalam memprediksi kelas minoritas, yang sering kali lebih sulit diprediksi dengan akurat. Selain itu, heterogenitas data juga menjadi tantangan besar, karena data medis sering kali mencakup berbagai jenis informasi, seperti data teks (catatan medis), data numerik (hasil laboratorium), dan data gambar (hasil radiologi). Integrasi berbagai jenis data ini memerlukan pendekatan yang lebih kompleks dan canggih untuk menggabungkan informasi yang saling melengkapi. Tantangan lainnya adalah privasi dan keamanan data, di mana pemanfaatan data medis harus mematuhi regulasi yang ketat seperti GDPR, yang mengharuskan perlindungan data pasien. Solusi seperti differential privacy dan federated learning dapat diterapkan untuk melatih model tanpa perlu memindahkan data mentah. Studi dalam [28] mengusulkan differential privacy berbasis Renyi sebagai solusi inovatif untuk meningkatkan keamanan data medis dalam pengolahan model deep learning tanpa mengorbankan akurasi. Sementara teknik homomorphic encryption memungkinkan analisis data terenkripsi tanpa membuka kerahasiaannya. Interpretabilitas model juga menjadi isu penting, karena model deep learning sering kali dianggap sebagai "black box," yang membuat sulit bagi klinisi untuk memahami dasar dari suatu prediksi. Terakhir, keterbatasan data annotated menjadi masalah lain, karena data medis dengan label yang akurat sulit didapatkan, mengingat proses annotasi membutuhkan biaya tinggi dan tenaga ahli yang terbatas.

3.3.2. Peluang Pengembangan

Beberapa peluang pengembangan teknologi deep learning dalam prediksi readmisi pasien dapat memberikan solusi terhadap tantangan yang ada. Salah satunya adalah integrasi data multimodal, di mana penggunaan model hybrid yang mampu menggabungkan berbagai jenis data medis, seperti data teks, numerik, dan gambar, dapat meningkatkan akurasi prediksi dan memberikan wawasan yang lebih komprehensif. Studi dalam [29] menunjukkan bahwa pemanfaatan fitur rekam medis elektronik yang lebih terstruktur, seperti pencatatan pola kunjungan pasien, dapat meningkatkan prediksi resiko readmisi dengan lebih baik. Selain itu, penggunaan transfer learning dapat dimanfaatkan untuk mengatasi keterbatasan data annotated, dengan memanfaatkan pengetahuan dan model yang telah dilatih pada domain lain untuk meningkatkan performa model meskipun dengan data terbatas. Dalam hal privasi data, privasi diferensial menjadi teknik yang menjanjikan untuk memastikan bahwa data pasien tetap aman tanpa mengorbankan kegunaan analisis. Sementara itu, pengembangan model Explainable AI (XAI) dapat membantu menciptakan model yang memberikan interpretasi jelas terhadap hasil prediksi, sehingga meningkatkan kepercayaan dan pemahaman klinisi terhadap keputusan yang dihasilkan oleh model. Terakhir, peningkatan kinerja real-time menjadi peluang penting, karena optimasi model untuk penerapan dalam lingkungan klinis secara real-time dapat memberikan dampak langsung pada pengambilan keputusan medis yang lebih cepat dan tepat.

Tantangan dan peluang ini menunjukkan bahwa meskipun penerapan deep learning untuk prediksi readmisi pasien menghadapi hambatan signifikan, inovasi teknologi dan metodologi dapat mengatasi hambatan tersebut dan membawa dampak positif pada bidang kesehatan. Contohnya, federated learning telah digunakan untuk memungkinkan pelatihan model tanpa memindahkan data pasien, seperti pada studi yang menunjukkan pengurangan risiko privasi tanpa mengurangi akurasi prediksi. Selain itu, teknik explainable AI (XAI) telah berhasil meningkatkan kepercayaan klinisi terhadap hasil model prediktif dengan memberikan interpretasi yang mudah dipahami.

4. DISKUSI

Hasil penelitian ini mendukung beberapa temuan utama dalam literatur terkait, sekaligus memberikan kontribusi baru yang relevan. Algoritma Long Short-Term Memory (LSTM) dan variannya telah diidentifikasi sebagai pendekatan yang paling efektif untuk menangkap pola temporal dalam data rekam medis elektronik (Electronic Health Records/EHR). Studi dalam [15] menunjukkan bahwa penerapan deep learning berbasis LSTM dalam analisis rekam medis dapat meningkatkan deteksi pasien dengan risiko tinggi mengalami gagal jantung, memungkinkan intervensi medis yang lebih cepat dan akurat. Penelitian ini sejalan dengan temuan dalam [5], yang menunjukkan bahwa LSTM mencapai Area Under the Curve (AUC) sebesar 88.4%, melebihi metode tradisional seperti regresi logistik yang hanya mencapai AUC sekitar 75%. Selain itu, varian seperti Bi-LSTM dan Time-Aware LSTM semakin memperkuat kemampuan dalam analisis temporal dengan mempertimbangkan interval waktu antar data [16].

Namun, penelitian ini juga menyoroti peran penting algoritma lain seperti Convolutional Neural Networks (CNN) dan Transformer. CNN, yang unggul dalam analisis teks tidak terstruktur, telah digunakan secara efektif untuk prediksi berbasis catatan medis, seperti yang ditunjukkan dalam [4]. Transformer, meskipun relatif baru dalam aplikasi prediksi readmisi pasien, menunjukkan potensi signifikan dalam menangani dataset besar dan heterogen, sebagaimana diilustrasikan dalam [6].

Heterogenitas data medis, termasuk teks, numerik, dan gambar, tetap menjadi tantangan utama. Penelitian ini mendukung temuan dalam [25], yang menunjukkan bahwa teknik integrasi data multimodal, seperti kombinasi CNN dan LSTM, dapat meningkatkan akurasi prediksi sekaligus memberikan interpretabilitas tambahan. Studi dalam [30] juga mengeksplorasi trade-off antara akurasi dan interpretabilitas dalam model machine learning untuk prediksi readmisi pasien gagal jantung, menunjukkan bahwa explainability dapat meningkatkan kepercayaan tanpa mengorbankan akurasi. Di sisi lain, penelitian ini memberikan perspektif baru dengan menyoroti peluang adopsi teknologi Explainable AI (XAI) untuk meningkatkan kepercayaan klinisi terhadap prediksi model, seperti yang juga dicatat dalam [17].

Tantangan lain, seperti ketidakseimbangan data, juga diangkat dalam penelitian ini. Pendekatan seperti Generative Adversarial Networks (GANs) untuk mengatasi masalah ini telah terbukti efektif dalam studi dalam [25], tetapi penelitian ini menunjukkan bahwa teknik federated learning juga dapat menjadi solusi untuk mengurangi risiko privasi tanpa mengurangi akurasi prediksi.

Dalam konteks ini, penelitian ini memberikan kontribusi dengan menawarkan kerangka kerja komprehensif untuk mengevaluasi algoritma deep learning berdasarkan performa, interpretabilitas, dan adaptabilitas dalam skenario klinis. Hal ini memperluas literatur dengan mengidentifikasi solusi inovatif untuk tantangan yang ada dan membuka peluang pengembangan teknologi di masa depan.

5. KESIMPULAN

Penelitian ini telah mengidentifikasi dan mengevaluasi berbagai algoritma deep learning yang digunakan untuk prediksi readmisi pasien, menganalisis performa algoritma berdasarkan metrik standar, dan menyoroti tantangan serta peluang yang relevan dalam penerapannya. Temuan utama dari penelitian ini adalah sebagai berikut:

Algoritma LSTM dan variannya, seperti Bi-LSTM dan Time-Aware LSTM, menunjukkan performa unggul dalam menangkap pola temporal dari data EHR. Model berbasis CNN memberikan kontribusi signifikan dalam menganalisis teks tidak terstruktur, sementara model Transformer mulai mendapatkan perhatian untuk pengolahan dataset yang lebih kompleks. Penggunaan model hybrid, seperti kombinasi BERTopic dan LSTM, membuktikan kemampuannya dalam meningkatkan akurasi prediksi sambil memberikan interpretabilitas tambahan.

Dalam hal performa, metrik seperti AUC dan F1 Score menjadi indikator utama. LSTM dengan AUC sebesar 88.4% dan Autoencoders dengan akurasi 92.4% menunjukkan bahwa algoritma deep learning memiliki potensi besar dibandingkan dengan metode tradisional. Namun, interpretabilitas model tetap menjadi tantangan, terutama untuk aplikasi klinis.

Temuan penelitian ini memiliki beberapa implikasi praktis yang signifikan untuk pengembangan sistem kesehatan. Dengan mengadopsi algoritma deep learning, rumah sakit dan penyedia layanan kesehatan dapat lebih proaktif dalam mengidentifikasi pasien berisiko tinggi untuk readmisi, sehingga memungkinkan intervensi dini yang lebih efektif. Model seperti LSTM dan CNN, yang terbukti unggul dalam analisis data temporal dan tidak terstruktur, dapat diintegrasikan ke dalam sistem manajemen rumah sakit untuk meningkatkan pengambilan keputusan berbasis data.

Selain itu, penggunaan teknologi seperti Explainable AI (XAI) dapat membantu menjembatani kesenjangan antara model deep learning dan kebutuhan klinis, dengan memberikan wawasan yang dapat dipahami oleh praktisi medis. Solusi seperti federated learning juga memungkinkan pelatihan model tanpa mengorbankan privasi pasien, mendukung kepatuhan terhadap regulasi seperti GDPR.

Tantangan utama seperti ketidakseimbangan data dan heterogenitas data dapat diatasi melalui integrasi data multimodal dan penggunaan teknik transfer learning, yang memungkinkan optimalisasi model dengan dataset yang lebih kecil tetapi relevan. Hal ini membuka peluang bagi penyedia layanan kesehatan dengan sumber daya terbatas untuk memanfaatkan teknologi canggih dalam skala yang lebih luas.

Kesimpulannya, pengembangan algoritma deep learning untuk prediksi readmisi pasien harus mempertimbangkan kombinasi performa kuantitatif, interpretabilitas, dan keamanan data. Dengan tantangan yang ada, peluang teknologi seperti federated learning, Explainable AI, dan integrasi data multimodal menjadi semakin relevan untuk diterapkan di masa depan, memberikan dampak positif yang signifikan dalam sistem kesehatan global.

DAFTAR PUSTAKA

- [1] "Medicare Drug Price Negotiation | CMS." Accessed: Jan. 22, 2025. [Online]. Available: <https://www.cms.gov/inflation-reduction-act-and-medicare/medicare-drug-price-negotiation>
- [2] "Profil Kesehatan Indonesia 2023." Accessed: Jan. 22, 2025. [Online]. Available: <https://www.kemkes.go.id/profil-kesehatan-indonesia-2023>
- [3] Z. Wu *et al.*, "Medical long-tailed learning for imbalanced data: Bibliometric analysis," *Comput. Methods Programs Biomed.*, vol. 247, p. 108106, Apr. 2024, doi: 10.1016/j.cmpb.2024.108106.
- [4] X. Liu, Y. Chen, J. Bae, H. Li, J. Johnston, and T. Sanger, "Predicting Heart Failure Readmission from Clinical Notes Using Deep Learning," in *2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, Nov. 2019, pp. 2642–2648. doi: 10.1109/BIBM47256.2019.8983095.

- [5] J. Xie, B. Zhang, J. Ma, D. Zeng, and J. Lo-Ciganic, "Readmission Prediction for Patients with Heterogeneous Medical History: A Trajectory-Based Deep Learning Approach," *ACM Trans Manage Inf Syst*, vol. 13, no. 2, p. 14:1-14:27, Oktober 2021, doi: 10.1145/3468780.
- [6] H.-Y. Chen, H.-M. Wang, C.-H. Lin, R. Yang, and C.-C. Lee, "Lung Cancer Prediction Using Electronic Claims Records: A Transformer-Based Approach," *IEEE J. Biomed. Health Inform.*, vol. 27, no. 12, pp. 6062–6073, Dec. 2023, doi: 10.1109/JBHI.2023.3324191.
- [7] G. Huang, Y. Li, S. Jameel, Y. Long, and G. Papanastasiou, "From explainable to interpretable deep learning for natural language processing in healthcare: How far from reality?," *Comput. Struct. Biotechnol. J.*, vol. 24, pp. 362–373, Dec. 2024, doi: 10.1016/j.csbj.2024.05.004.
- [8] Y. Shahzad, H. Javed, H. Farman, J. Ahmad, B. Jan, and A. A. Nassani, "Optimized Predictive Framework for Healthcare Through Deep Learning," *Comput. Mater. Contin.*, vol. 67, no. 2, pp. 2463–2480, 2021, doi: 10.32604/cmc.2021.014904.
- [9] T. Khanna and S. Mathur, "An Enhanced Analysis of Cloud-Based Deep Learning Model in Smart Healthcare Management," *2024 2nd Int. Conf. Disruptive Technol. ICDT*, pp. 705–710, Mar. 2024, doi: 10.1109/ICDT61202.2024.10489824.
- [10] M. J. Page *et al.*, "The PRISMA 2020 statement: an updated guideline for reporting systematic reviews," *BMJ*, vol. 372, p. n71, Mar. 2021, doi: 10.1136/bmj.n71.
- [11] J. F. Silva and S. Matos, "Modelling patient trajectories using multimodal information," *J. Biomed. Inform.*, vol. 134, p. 104195, Oct. 2022, doi: 10.1016/j.jbi.2022.104195.
- [12] B. Davazdahemami, P. Peng, and D. Delen, "A deep learning approach for predicting early bounces-backs to the emergency departments," *Healthc. Anal.*, vol. 2, p. 100018, Nov. 2022, doi: 10.1016/j.health.2022.100018.
- [13] Z. Xu, Q. Zhang, and P. S. F. Yip, "Predicting post-discharge self-harm incidents using disease comorbidity networks: A retrospective machine learning study," *J. Affect. Disord.*, vol. 277, pp. 402–409, Dec. 2020, doi: 10.1016/j.jad.2020.08.044.
- [14] C. Qian, P. Leelaprachakul, M. Landers, C. Low, A. K. Dey, and A. Doryab, "Prediction of Hospital Readmission from Longitudinal Mobile Data Streams," *Sensors*, vol. 21, no. 22, p. 7510, Nov. 2021, doi: 10.3390/s21227510.
- [15] Z. Wang *et al.*, "Using Deep Learning to Identify High-Risk Patients with Heart Failure with Reduced Ejection Fraction," *J. Health Econ. Outcomes Res.*, vol. 8, no. 2, pp. 6–13, Jul. 2021, doi: 10.36469/jheor.2021.25753.
- [16] J. Q. Sheng, P. J.-H. Hu, X. Liu, T.-S. Huang, and Y. H. Chen, "Predictive Analytics for Care and Management of Patients With Acute Diseases: Deep Learning-Based Method to Predict Crucial Complication Phenotypes," *J. Med. Internet Res.*, vol. 23, no. 2, p. e18372, Feb. 2021, doi: 10.2196/18372.
- [17] S. J. Im, Y. Xu, and J. Watson, "Semantic-based Attention model for Hospital Readmission Prediction," in *2022 IEEE International Conference on Big Data (Big Data)*, Dec. 2022, pp. 1836–1841. doi: 10.1109/BigData55660.2022.10020315.
- [18] W. Liu *et al.*, "Predicting 30-day hospital readmissions using artificial neural networks with medical code embedding," *PLOS ONE*, vol. 15, no. 4, p. e0221606, Apr. 2020, doi: 10.1371/journal.pone.0221606.
- [19] C.-C. Chiu, C.-M. Wu, T.-N. Chien, L.-J. Kao, and C. Li, "Predicting ICU Readmission from Electronic Health Records via BERTopic with Long Short Term Memory Network Approach," *J. Clin. Med.*, vol. 13, no. 18, Art. no. 18, Jan. 2024, doi: 10.3390/jcm13185503.
- [20] H.-Y. Chen, H.-M. Wang, C.-H. Lin, R. Yang, and C.-C. Lee, "Lung Cancer Prediction Using Electronic Claims Records: A Transformer-Based Approach," *IEEE J. Biomed. Health Inform.*, vol. 27, no. 12, pp. 6062–6073, Dec. 2023, doi: 10.1109/JBHI.2023.3324191.
- [21] T. B. Sivakumar, A. Malakar, L. S. G. Shailaja, E. Kalaivani, and D. Babu K, "Enhanced Diabetes Prediction Using Deep Autoencoder Framework and Electronic Health Records," *2024 Second Int. Conf. Adv. Inf. Technol. ICAIT*, pp. 1–5, Jul. 2024, doi: 10.1109/ICAIT61638.2024.10690358.

-
- [22] J. Q. Sheng, P. J.-H. Hu, X. Liu, T.-S. Huang, and Y. H. Chen, “Predictive Analytics for Care and Management of Patients With Acute Diseases: Deep Learning-Based Method to Predict Crucial Complication Phenotypes,” *J. Med. Internet Res.*, vol. 23, no. 2, p. e18372, Feb. 2021, doi: 10.2196/18372.
 - [23] S. Ali, S. El-Sappagh, F. Ali, M. Imran, and T. Abuhmed, “Multitask Deep Learning for Cost-Effective Prediction of Patient’s Length of Stay and Readmission State Using Multimodal Physical Activity Sensory Data,” *IEEE J. Biomed. Health Inform.*, vol. 26, no. 12, pp. 5793–5804, Dec. 2022, doi: 10.1109/JBHI.2022.3202178.
 - [24] Y. Zhang *et al.*, “Development of a prediction model for the risk of 30-day unplanned readmission in older patients with heart failure: A multicenter retrospective study,” *Nutr. Metab. Cardiovasc. Dis.*, vol. 33, no. 10, pp. 1878–1887, Oct. 2023, doi: 10.1016/j.numecd.2023.05.034.
 - [25] Z. Zhou, C. Fu, and R. Weibel, “SpaGAN: A spatially-aware generative adversarial network for building generalization in image maps,” *Int. J. Appl. Earth Obs. Geoinformation*, vol. 135, p. 104236, Dec. 2024, doi: 10.1016/j.jag.2024.104236.
 - [26] Al-Azhar University *et al.*, “Enhanced Predictive Modelling for 30-Day Readmission Diabetes Patients Based on Data Normalization Analysis,” *Int. J. Intell. Eng. Syst.*, vol. 14, no. 4, pp. 204–216, Aug. 2021, doi: 10.22266/ijies2021.0831.19.
 - [27] X. Liu, Y. Chen, J. Bae, H. Li, J. Johnston, and T. Sanger, “Predicting Heart Failure Readmission from Clinical Notes Using Deep Learning,” in *2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, San Diego, CA, USA: IEEE, Nov. 2019, pp. 2642–2648. doi: 10.1109/BIBM47256.2019.8983095.
 - [28] O. T. Odeyomi, H. Karnati, and A. Smith, “Preserving Medical Data with Renyi Differential Privacy,” *2024 IEEE World AI IoT Congr. AIoT*, pp. 244–251, May 2024, doi: 10.1109/AIIoT61789.2024.10578985.
 - [29] M.-K. Pham *et al.*, “Forecasting Patient Early Readmission from Irish Hospital Discharge Records Using Conventional Machine Learning Models,” *Diagnostics*, vol. 14, no. 21, Art. no. 21, Jan. 2024, doi: 10.3390/diagnostics14212405.
 - [30] A. Soliman, B. Agvall, K. Etminani, O. Hamed, and M. Lingman, “The Price of Explainability in Machine Learning Models for 100-Day Readmission Prediction in Heart Failure: Retrospective, Comparative, Machine Learning Study,” *J. Med. Internet Res.*, vol. 25, no. 1, p. e46934, Oct. 2023, doi: 10.2196/46934.