

BAB I

PENDAHULUAN

1.1 Latar Belakang

Lama rawat inap pasien atau *Length of Stay* (LoS) merupakan waktu yang dihitung sejak hari pertama pasien masuk ke rumah sakit hingga hari keluar yang bertujuan untuk melakukan perawatan, keluarnya pasien bisa dikarenakan sembuh, rawat jalan ataupun meninggal dunia (Adawiyah dkk., 2021). LoS merupakan salah satu indikator penting untuk evaluasi kualitas layanan dan efisiensi operasional rumah sakit (Nasiatin, 2025). Lama rawat inap pasien berdampak signifikan, baik bagi pasien maupun rumah sakit. Bagi pasien, LoS dapat meningkatkan biaya perawatan, menurunkan tingkat kepuasan, serta meningkatkan risiko infeksi nosokomial. Sementara bagi rumah sakit, dampaknya meliputi peningkatan biaya operasional, berkurangnya ketersediaan tempat tidur, dan bertambahnya beban kerja tenaga medis (Sunardi & Pradiarti, 2025).

Berdasarkan data dari *Health at a Glance* tahun 2025 rata-rata LoS pada negara anggota *Organization for Economic Cooperation and Development* (OECD) adalah 6,4 hari (*Health at a Glance 2025*, 2025), sedangkan aturan dari Kementerian Kesehatan Indonesia menyebutkan bahwa rata-rata lama rawat inap yang ideal berkisar di 6-9 hari (Fani dkk., 2024). Mengacu pada data tersebut, dapat disimpulkan bahwa manajemen LoS yang efektif sangat penting dilakukan untuk memastikan durasi rawat inap pasien berada pada rentang yang optimal.

Dataset yang umum digunakan untuk pemodelan LoS berasal dari rekam medis elektronik (*Electronic Health Records/EHR*) yang tersimpan sebagai data tabular terstruktur. Dataset jenis ini umumnya memuat kombinasi fitur numerik dan kategorik, seperti informasi administratif, demografi pasien, diagnosis utama, komorbiditas, prosedur, dan ringkasan hasil pemeriksaan klinis yang terstruktur (Ferrão dkk., 2021). Karakteristik data tersebut cenderung heterogen, memiliki *missing value*, dan memiliki pola hubungan yang tidak linier serta interaksi yang kompleks antar variabel (Ren dkk., 2025).

Berbagai penelitian terdahulu telah menerapkan metode *machine learning* untuk prediksi LoS, dengan pendekatan yang beragam seperti regresi linier sebagai model dasar yang *interpretable* namun kurang fleksibel dalam menangkap pola nonlinier pada data medis yang kompleks (Jain dkk., 2024). Pendekatan berbasis pohon seperti *Random Forest* yang merupakan *ensemble* dari banyak *decision trees* melalui teknik *bagging* mampu mengatasi keterbatasan tersebut (Puspita dkk., 2023), namun tetap memiliki kelemahan dalam menangkap ketergantungan jangka panjang (*long-term dependencies*) pada data sekuensial seperti rekam medis pasien (Hu & Szymczak, 2023).

Sementara itu, XGBoost sebagai metode *ensemble boosting* terbukti unggul dalam berbagai tugas klasifikasi dan regresi untuk prediksi LoS (Peng & Gao, 2025), tetapi model berbasis *tree* seperti XGBoost efektif pada data tabular, interaksi fitur yang dipelajari bersifat implisit dan terbatas secara lokal dalam struktur pohon (Grinsztajn dkk., 2022). Seiring meningkatnya kesadaran akan privasi data pasien, *federated learning* muncul sebagai paradigma baru yang

memungkinkan pelatihan model secara kolaboratif antarinstansi tanpa mentransfer data sensitif (Balik, 2024). Namun, pendekatan ini masih menghadapi tantangan berupa heterogenitas data antarklien (non-IID data) yang dapat menurunkan performa model serta memerlukan mekanisme agregasi yang canggih untuk menjamin konvergensi (K.-Y. Chen dkk., 2025).

Seiring berkembangnya *deep learning*, arsitektur *Transformer* berbasis mekanisme self-attention menjadi salah satu pendekatan penting untuk mempelajari ketergantungan (dependensi) yang kompleks. Pendekatan ini juga mulai diadaptasi untuk pemodelan data tabular. Salah satu desain arsitektur yang dibuat khusus untuk data tabular adalah *Feature Tokenizer Transformer* (FT-Transformer) (Asal & Yalciner, 2026). Model ini menggunakan mekanisme *self-attention* untuk memahami interaksi antar fitur secara menyeluruh, sehingga berpotensi lebih baik dalam menangkap hubungan rumit yang mempengaruhi LoS dibandingkan dengan model *machine learning* dan *deep learning* tradisional (Choi dkk., 2024). Studi komparatif pada *deep learning* untuk data tabular melaporkan bahwa varian *Transformer* yang disesuaikan untuk tabular dapat menjadi *baseline* kuat dan kompetitif pada beragam tugas tabular (Gorishniy dkk., 2021). Namun, penerapan arsitektur *Transformer* dalam prediksi LoS masih cukup terbatas dan belum banyak diteliti secara mendalam.

Selain akurasi prediksi, pemahaman mengenai model juga menjadi fokus utama pada penelitian ini, di mana hasil yang didapatkan dari model tidak bersifat *black box*, dapat dipahami, dan dipertanggungjawabkan, baik untuk kepentingan klinis maupun kebijakan layanan. Pendekatan *eXplainable Artificial Intelligence*

(XAI) semakin sering diadopsi dalam model prediktif untuk meningkatkan transparansi dan interpretabilitas hasil model (Mustafa dkk., 2025). Salah satu teknik XAI yang populer adalah SHAP (*SHapley Additive exPlanations*), yang dapat menjelaskan peran masing-masing fitur dalam hasil prediksi dengan mengacu pada teori nilai Shapley (Roder dkk., 2021). Penelitian sebelumnya telah membuktikan bahwa SHAP efektif dalam meningkatkan kejelasan model dan membantu menemukan faktor-faktor yang berdampak signifikan terhadap durasi rawat inap pasien (Jain dkk., 2024).

Meskipun beberapa penelitian telah menggabungkan *machine learning* dengan pendekatan XAI untuk memprediksi LoS, mayoritas penelitian masih mengutamakan algoritma konvensional atau *ensemble learning*. Pemanfaatan arsitektur *Transformer* yang dirancang khusus untuk data tabular seperti FT-*Transformer* dengan kombinasi interpretasi menggunakan metode XAI SHAP untuk memprediksi LoS masih sangat minim. Hal ini menandakan adanya celah dalam penelitian (*research gap*) yang perlu diteliti lebih dalam.

Berdasarkan penjelasan di atas, tujuan penelitian ini adalah mengembangkan model prediksi *Length of Stay* menggunakan FT-*Transformer* dan pendekatan interpretasi dengan metode XAI SHAP. Diharapkan penelitian ini dapat menghasilkan model yang memberikan kinerja prediksi terbaik serta mampu memberikan penjelasan yang jelas dan mudah dipahami mengenai faktor-faktor yang memengaruhi lamanya masa rawat inap pasien, sehingga dapat mendukung pengambilan keputusan yang lebih baik dalam pengelolaan layanan kesehatan.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, rumusan masalah pada penelitian ini meliputi:

1. Bagaimana pemodelan data tabular yang terdiri dari fitur numerik dan kategorikal dengan hubungan nonlinier antarfitur menggunakan model *deep learning* FT-Transformer untuk memprediksi LoS?
2. Bagaimana penerapan XAI menggunakan metode SHAP dalam menjelaskan kontribusi setiap fitur terhadap prediksi LoS pada model FT-Transformer?
3. Bagaimana pengaruh jumlah fitur (*top-k*) berdasarkan peringkat nilai SHAP terhadap performa prediksi LoS?

1.3 Tujuan Penelitian

Tujuan penelitian yang ingin dicapai berdasarkan latar belakang yang dipaparkan sebagai berikut:

1. Menerapkan model FT-Transformer untuk menangkap hubungan nonlinier antara fitur numerik dan kategorikal dalam memprediksi LoS pada data tabular.
2. Mengimplementasikan model XAI dengan metode SHAP untuk menganalisis dan menjelaskan kontribusi setiap fitur terhadap hasil prediksi LoS.
3. Menganalisis pengaruh variasi jumlah fitur (*top-k*) berdasarkan peringkat kepentingan SHAP terhadap performa prediksi LoS pada skenario $k = 5, 10, 15, 20$, dan semua fitur.

1.4 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan kontribusi pada sisi akademis maupun praktis, diantaranya:

1. Memberikan kontribusi dalam pengembangan metode prediksi pada data tabular dengan mengeksplorasi model *deep learning* berbasis *transformer* untuk prediksi LoS.
2. Menambahkan referensi terkait penerapan XAI SHAP yang dikombinasikan dengan *deep learning* dan dengan berbasis data tabular medis.
3. Memberikan referensi awal mengenai pemanfaatan model prediksi LoS yang berpotensi mendukung perencanaan kapasitas tempat tidur dan alokasi sumber daya rumah sakit.

1.5 Batasan Masalah

Beberapa batasan masalah yang perlu diperhatikan dalam penelitian ini, sebagai berikut:

1. Dataset yang digunakan bukanlah dataset klinis yang diperoleh langsung dari instansi medis atau rumah sakit melainkan dari dataset publik Microsoft untuk prediksi LoS.
2. Evaluasi performa model dibatasi pada matrik evaluasi MAE, RMSE, RAE, dan RSE tanpa dilakukan validasi lebih lanjut.
3. Penelitian ini tidak melakukan analisis atau perbandingan terhadap waktu komputasi model.

4. Hasil penelitian yang didapatkan tidak divalidasi oleh tenaga ahli di bidang kesehatan.
5. Skenario evaluasi seleksi fitur dibatasi pada Top-5, Top-10, Top-15, Top-20, dan seluruh fitur berdasarkan peringkat nilai SHAP, dengan mempertimbangkan jumlah fitur pada dataset sebanyak 25 fitur.

1.6 Sistematika Penulisan

Adapun sistematika penulisan yang digunakan pada penelitian ini berdasarkan pedoman Tugas Akhir di Universitas Siliwangi sebagai berikut:

BAB I PENDAHULUAN

Bab ini berisi beberapa sub pembahasan seperti latar belakang penelitian, rumusan penelitian, tujuan penelitian, manfaat penelitian, batasan penelitian, serta sistematika penulisan.

BAB II LANDASAN TEORI

Bab ini berisi pembahasan mengenai teori-teori yang mendukung penelitian, termasuk konsep dan metode yang digunakan pada penelitian. Selain itu, bab ini berisi penelitian-penelitian sebelumnya yang dipaparkan pada *state of the art* dan matriks penelitian yang berisi *research gap* penelitian yang dilakukan dengan penelitian sebelumnya.

BAB III METODOLOGI PENELITIAN

Bab ini berisi penjelasan mengenai metodologi penelitian mulai dari *roadmap* penelitian dan tahapan-tahapan penelitian yang dilakukan yaitu studi

literatur, pengumpulan data, *preprocessing*, optimasi *hyperparameter*, penerapan model, seleksi fitur, evaluasi model, dan interpretasi.

BAB IV HASIL DAN PEMBAHASAN

Bab ini berisi penjelasan terkait hasil penelitian dan pembahasan terkait rancangan penelitian yang dijelaskan pada bab sebelumnya. Pembahasan meliputi rancangan eksperimen, arsitektur sistem, pengumpulan data, *preprocessing*, optimasi *hyperparameter*, penerapan model, seleksi fitur, evaluasi model, interpretasi, dan analisis ancaman terhadap validitas.

BAB V KESIMPULAN DAN SARAN

Bab ini berisi kesimpulan dari penelitian yang telah dilakukan dan saran yang bisa dilakukan untuk pengembangan penelitian selanjutnya.