

Prediksi Waktu Tunggu Pada Sistem Antrean Pasien Berbasis *Mobile* Menggunakan Algoritma *Random Forest*

¹Rani Tasya Samosir, ^{2*}Suroso, ³Irma Salamah

^{1,2*,3}Teknik Telekomunikasi, Jurusan Teknik Elektro, Politeknik Negeri Sriwijaya, Palembang, Indonesia.

*Korespondensi: suroso.0719@gmail.com

Submit : 30 Mei 2026 | Diterima : 21 Juni 2026 | Terbit : 15 Juli 2026

ABSTRACT

Patient queue management is an important aspect of improving healthcare service quality because the absence of waiting time estimation information can create uncertainty for patients. This study aims to design and develop a mobile-based patient queue system integrated with the Random Forest algorithm to predict patient waiting time. The prediction model was developed using 208 historical patient service records, with 80% of the data used for training and 20% for testing. Service type and previous queue were used as input variables, while waiting time was used as the prediction target. Model performance was evaluated using the coefficient of determination (R^2) and Mean Absolute Error (MAE), while system functionality was assessed using Black Box Testing. The evaluation results show that the Random Forest model achieved an R^2 score of 0.9773 and an MAE of 9.77 minutes, indicating excellent prediction performance. In addition, functional testing confirmed that all system features operated as expected. The developed system provides patients with waiting time estimation, helping reduce uncertainty, improve queue management efficiency, and support better healthcare service quality.

Keywords: Healthcare Services; Mobile Application; Patient Queue System; Random Forest; Waiting Time Prediction.

ABSTRAK

Pengelolaan antrean pasien merupakan salah satu aspek penting dalam meningkatkan kualitas pelayanan kesehatan karena ketidaktersediaan informasi estimasi waktu tunggu dapat menimbulkan ketidakpastian bagi pasien. Penelitian ini bertujuan merancang dan membangun sistem antrean pasien berbasis *mobile* yang terintegrasi dengan algoritma *Random Forest* untuk memprediksi waktu tunggu pelayanan. Model prediksi dibangun menggunakan 208 data historis pelayanan pasien yang dibagi menjadi 80% data latih dan 20% data uji. Variabel jenis layanan dan antrean sebelumnya digunakan sebagai masukan (*input*), sedangkan waktu tunggu digunakan sebagai target prediksi. Kinerja model dievaluasi menggunakan *R-Squared* (R^2) dan *Mean Absolute Error* (MAE), sedangkan fungsionalitas sistem diuji menggunakan metode *Black Box Testing*. Hasil evaluasi menunjukkan bahwa model *Random Forest* memperoleh nilai R^2 sebesar 0,9773 dan MAE sebesar 9,77 menit, yang menunjukkan bahwa model memiliki kemampuan prediksi yang sangat baik. Selain itu, hasil pengujian menunjukkan bahwa seluruh fitur sistem berfungsi sesuai dengan kebutuhan. Sistem yang dibangun mampu menyediakan informasi estimasi waktu tunggu kepada pasien, sehingga membantu mengurangi ketidakpastian, meningkatkan efisiensi pengelolaan antrean, serta mendukung peningkatan kualitas pelayanan kesehatan.

Kata Kunci: Pelayanan Kesehatan; Aplikasi *Mobile*; Sistem Antrean Pasien; *Random Forest*; Prediksi Waktu Tunggu.

PENDAHULUAN

Pelayanan kesehatan merupakan kebutuhan dasar masyarakat dalam menjaga serta meningkatkan kualitas hidup. Berbagai upaya pelayanan dilakukan baik secara individu maupun melalui organisasi dengan tujuan untuk memelihara, meningkatkan, dan memulihkan kondisi kesehatan masyarakat (Erawati et al., 2024). Sebagai bagian dari pelayanan publik, pelayanan kesehatan harus diselenggarakan dengan baik agar mampu memenuhi kebutuhan masyarakat

secara optimal (Hariyoko et al., 2021). Oleh karena itu, fasilitas pelayanan kesehatan dituntut untuk memberikan layanan yang efektif, efisien, dan berorientasi pada kepuasan pasien.

Pengelolaan antrean pasien adalah salah satu masalah yang masih sering ditemui dalam layanan kesehatan. Antrean terjadi ketika jumlah pasien melebihi kapasitas layanan yang tersedia, baik dari sisi tenaga medis maupun fasilitas pelayanan, sehingga menimbulkan penumpukan pasien yang berdampak pada meningkatnya waktu tunggu layanan yang berpotensi menimbulkan keluhan dari pasien (Rahmadini & Rahman, 2024). Waktu tunggu bahkan menjadi salah satu standar yang dapat digunakan untuk menilai kualitas pelayanan di rumah sakit dan puskesmas. (Dewi et al., 2020). Selain durasi antrean yang panjang, ketidakpastian terkait waktu pasien akan mendapatkan pelayanan juga menjadi faktor yang memengaruhi tingkat kepuasan pasien. Ketidakpastian waktu tunggu tersebut dapat menurunkan kepuasan pasien, sehingga adanya prediksi yang akurat dapat meningkatkan kepuasan pasien dengan mengurangi ketidakpastian (Taton et al., 2025).

Berdasarkan hasil observasi yang dilakukan, informasi mengenai prediksi waktu tunggu pasien belum tersedia sehingga pasien masih mengalami ketidakpastian mengenai waktu pelayanan yang akan diterima. Kondisi ini menunjukkan bahwa sistem antrean tidak hanya perlu mampu mengelola urutan pelayanan pasien, tetapi juga perlu menyediakan informasi yang dapat membantu pasien dalam memperkirakan waktu tunggu sebelum memperoleh layanan.

Seiring dengan pesatnya perkembangan teknologi informasi, berbagai pendekatan yang memanfaatkan kecerdasan buatan semakin luas diterapkan untuk membantu proses penyelesaian permasalahan di beragam sektor, termasuk pelayanan kesehatan. Salah satu pendekatan yang umum digunakan adalah *machine learning*, yang merupakan cabang utama dari *Artificial Intelligence* (AI) dengan fokus mempelajari pola data dan menghasilkan prediksi berdasarkan informasi yang tersedia (Roihan et al., 2020). *Machine learning* (ML) mampu menemukan serta mengenali pola-pola khusus dalam suatu kumpulan data (Chazar & Widhiaputra, 2020) serta dapat mengidentifikasi pola dalam data historis untuk memprediksi waktu tunggu dengan tingkat akurasi yang lebih baik dibandingkan metode statistik konvensional (Gupta & Sharma, 2025).

Untuk mendukung proses prediksi tersebut, beberapa algoritma dapat digunakan, salah satunya adalah *Random Forest*. Algoritma ini membangun sejumlah pohon keputusan dari sampel data yang dipilih secara acak (Jimy & Siregar, 2025), kemudian menggabungkan hasil dari seluruh *decision tree* yang dilatih menggunakan subset data pelatihan (Sari & Sari, 2025). Pendekatan ini menghasilkan prediksi yang lebih stabil serta konsisten dalam mengenali pola pada data.

Kemampuan *Random Forest* telah dibuktikan pada berbagai penelitian sebelumnya. Himawan (2025) mengembangkan aplikasi antrean berbasis *mobile* untuk puskesmas yang membantu mengurangi waktu tunggu melalui layanan pendaftaran secara *online*, namun penelitian tersebut belum menyediakan fitur prediksi waktu tunggu pelayanan. Guo et al. (2025) menerapkan *Random Forest* untuk memprediksi waktu tunggu pelayanan medis dan menunjukkan performa prediksi yang baik, tetapi masih terbatas pada jenis layanan tertentu. Munggaran et al. (2025) juga menunjukkan bahwa *Random Forest* mampu menghasilkan prediksi waktu tunggu dengan kinerja tinggi, namun penelitian tersebut masih berfokus pada model prediksi tanpa implementasi sistem yang dapat digunakan pasien. Yusuf et al. (2024) membuktikan bahwa *Random Forest* dapat membantu pengelolaan aliran pasien melalui pendekatan prediksi berbasis data. Budiman et al. (2023) juga menerapkan *Random Forest* untuk melakukan prediksi performa layanan kesehatan secara *near real-time*. Selain itu, Apriliah et al. (2021) menunjukkan kemampuan *Random Forest* untuk mengolah data yang kompleks dan membuat prediksi yang konsisten dalam berbagai kondisi data.

Berdasarkan permasalahan dan penelitian terdahulu tersebut, masih terdapat kebutuhan terhadap sistem yang mengintegrasikan pengelolaan antrean pasien berbasis *mobile* dengan model prediksi waktu tunggu menggunakan algoritma *Random Forest*. Oleh karena itu, penelitian ini membangun sistem antrean pasien berbasis *mobile* yang dilengkapi dengan algoritma *Random Forest* untuk prediksi waktu tunggu pelayanan. Sistem yang dibangun memanfaatkan data historis pelayanan pasien untuk menghasilkan informasi prediksi waktu tunggu yang dapat diakses melalui perangkat *mobile*. Dengan adanya sistem tersebut, pasien dapat memperoleh informasi antrean dan perkiraan waktu tunggu sebelum menerima pelayanan sehingga dapat membantu mengurangi ketidakpastian selama proses antrean berlangsung serta mendukung peningkatan kualitas pelayanan kesehatan.


METODE PENELITIAN

Tujuan penelitian ini adalah untuk membuat sistem antrian pasien berbasis *mobile* yang menggunakan algoritma *Random Forest* untuk memberikan informasi estimasi waktu tunggu pelayanan. Model prediksi dibangun berdasarkan data historis pelayanan pasien sehingga sistem dapat memperkirakan waktu tunggu berdasarkan kondisi antrian yang sedang berlangsung. Tahapan penelitian meliputi pengumpulan data, *preprocessing* data, pembagian *dataset*, pembangunan model *Random Forest*, evaluasi performa model, dan integrasi model ke dalam sistem antrian pasien berbasis *mobile*.

Arsitektur Sistem

Seperti yang ditunjukkan pada Gambar 1, arsitektur sistem terdiri atas tiga komponen utama, yaitu aplikasi *mobile* pasien, *server* sistem dan basis data, serta model prediksi *Random Forest*. Arsitektur sistem menggambarkan hubungan antar komponen dalam menghasilkan informasi estimasi waktu tunggu pasien.

Aplikasi *mobile* digunakan oleh pasien untuk melakukan pendaftaran antrian dan memperoleh informasi estimasi waktu tunggu pelayanan. Data pendaftaran yang dikirim dari aplikasi diterima oleh *server* dan disimpan ke dalam basis data. Selanjutnya, *server* mengirimkan data tersebut ke model *Random Forest* untuk menghasilkan prediksi waktu tunggu. Proses komunikasi antara *server* dan model prediksi dilakukan melalui layanan API sehingga hasil prediksi dapat diintegrasikan kembali ke dalam sistem. Hasil prediksi kemudian dikirim kembali ke *server*, disimpan ke dalam basis data, dan ditampilkan pada aplikasi *mobile* sehingga pasien dapat mengetahui perkiraan waktu pelayanan.



Gambar 1. Arsitektur Sistem Antrian Pasien

Pengumpulan Data

Penelitian ini menggunakan dataset pelayanan pasien dari Puskesmas Payakabung sebagai dasar pembangunan model prediksi waktu tunggu. Dataset diperoleh melalui observasi proses pelayanan antrian, wawancara dengan petugas puskesmas, serta data historis pelayanan pasien yang tersedia pada sistem informasi puskesmas.

Data historis yang diperoleh selanjutnya digunakan sebagai dataset penelitian untuk pembangunan model prediksi waktu tunggu pasien menggunakan algoritma *Random Forest*. Data yang digunakan meliputi jumlah antrian sebelumnya dan jenis layanan (poli) sebagai variabel masukan (*input*), sedangkan waktu tunggu digunakan sebagai variabel target (*output*) yang diprediksi oleh model. Sebelum digunakan dalam proses pelatihan dan pengujian, dataset terlebih dahulu melalui tahap *preprocessing* untuk memastikan data siap digunakan dalam pembentukan model.

Penerapan Algoritma *Random Forest*

Algoritma *Random Forest* diterapkan untuk menghasilkan prediksi waktu tunggu pasien menggunakan dataset pelayanan yang telah diproses. Algoritma ini membentuk sejumlah *decision tree* secara independen, kemudian menggabungkan hasil prediksi dari setiap pohon untuk menghasilkan estimasi waktu tunggu.

Tahapan penerapan algoritma *Random Forest* pada penelitian ini meliputi *preprocessing* data, pembagian dataset, pelatihan model, dan evaluasi model.

a. *Preprocessing Data*

Tahap *preprocessing* dilakukan untuk memastikan data siap digunakan pada proses pelatihan model. Pada tahap ini dilakukan pemeriksaan kualitas data, pembersihan data, pemilihan atribut yang relevan, serta penyesuaian format data agar dapat diproses oleh algoritma *Random Forest*.

b. *Pembagian Dataset*

Setelah data dinyatakan siap, dataset dibagi menjadi data latih dan data uji menggunakan rasio pembagian sebesar 80:20. Data latih digunakan untuk mempelajari pola-pola yang terdapat pada data. Sementara itu, data uji digunakan untuk menguji kemampuan model dalam melakukan prediksi terhadap data yang belum pernah digunakan sebelumnya.

c. *Pelatihan Model*

Proses pembentukan model dilakukan menggunakan *Random Forest Regressor*. Algoritma ini membangun sejumlah *decision tree* yang mempelajari pola berdasarkan data pelatihan. Setiap pohon menghasilkan nilai prediksi yang kemudian digabungkan untuk memperoleh hasil prediksi akhir. Data historis pelayanan pasien digunakan sebagai dasar pembelajaran model dalam mengenali hubungan antara kondisi antrean dan waktu tunggu pelayanan.

d. *Evaluasi Model*

Performa model dievaluasi dengan membandingkan hasil prediksi terhadap data aktual yang terdapat pada *dataset* pengujian. Evaluasi dilakukan menggunakan metrik *Mean Absolute Error* (MAE) dan koefisien determinasi (R^2).

MAE digunakan untuk mengukur rata-rata selisih mutlak antara nilai aktual dan nilai prediksi model. Rumus perhitungan MAE ditunjukkan pada Persamaan (1).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

Sementara itu, nilai R^2 digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data aktual. Rumus perhitungan R^2 ditunjukkan pada Persamaan (2).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

Semakin minim nilai MAE yang diperoleh, hal tersebut mengindikasikan tingkat kesalahan prediksi yang makin rendah. Sebaliknya, nilai R^2 yang kian mendekati angka 1 mencerminkan bahwa model mempunyai performa prediksi yang semakin akurat.

HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pembentukan model prediksi waktu tunggu menggunakan algoritma *Random Forest*, implementasi sistem antrean pasien berbasis *mobile*, serta hasil pengujian terhadap model dan sistem yang telah dibangun. Pembahasan disusun secara bertahap mulai dari penyusunan dataset penelitian, pembentukan model prediksi, implementasi sistem, hingga pengujian untuk mengevaluasi kinerja model serta memastikan seluruh fungsi sistem berjalan sesuai dengan kebutuhan pengguna.

Analisis Model Prediksi Waktu Tunggu

Model prediksi waktu tunggu dibangun menggunakan algoritma *Random Forest Regressor* untuk memperkirakan waktu tunggu pasien berdasarkan kondisi antrean yang sedang berlangsung. Proses pembentukan model diawali dengan penyusunan dataset penelitian, dilanjutkan dengan tahap *preprocessing*, pembagian data latih dan data uji, pelatihan model, serta evaluasi kinerja untuk mengetahui kemampuan model dalam melakukan prediksi.

a. *Dataset Penelitian*

Data penelitian diperoleh melalui observasi proses pelayanan antrean, wawancara dengan petugas, serta data pelayanan pasien yang tersedia pada sistem informasi puskesmas. Selanjutnya, data tersebut diproses melalui tahap *preprocessing* sehingga membentuk dataset penelitian yang digunakan dalam proses pelatihan dan pengujian model *Random Forest*.

Untuk meningkatkan jumlah dan variasi data, dilakukan proses augmentasi data sehingga diperoleh total dataset sebanyak 208 data. Penambahan data ini bertujuan memperkaya variasi pola pada dataset sehingga model dapat mempelajari hubungan antarvariabel dengan lebih baik selama proses pelatihan. Komposisi dataset penelitian ditunjukkan pada Tabel 1.

Tabel 1. Dataset Penelitian

Keterangan	Jumlah Data
Data Asli	145
Data Augmentasi	63
Total Dataset	208

b. *Preprocessing Data*

Sebelum digunakan dalam proses pembentukan model, data penelitian terlebih dahulu melalui tahap *preprocessing* untuk memastikan kualitas data telah sesuai dengan kebutuhan pemodelan menggunakan algoritma *Random Forest*.

Tahap awal dilakukan dengan pengecekan *missing value* pada seluruh variabel yang digunakan. Hasil pengecekan menunjukkan bahwa variabel jenis layanan, antrean sebelumnya, dan waktu tunggu tidak memiliki nilai yang hilang sehingga seluruh data dapat digunakan pada tahap selanjutnya. Hasil pengecekan *missing value* ditunjukkan pada Gambar 2.

```

jenis_layanan      0
antrean_sebelumnya  0
waktu_tunggu       0
dtype: int64

```

Gambar 2. Hasil Pengecekan *Missing Value*

Setelah proses *preprocessing* selesai dilakukan, diperoleh dataset penelitian yang menggunakan jenis layanan dan antrean sebelumnya sebagai variabel masukan (*input*), sedangkan waktu tunggu digunakan sebagai variabel target (*output*). Dataset tersebut selanjutnya digunakan pada proses pembagian data sebelum dilakukan pelatihan model.

c. *Pembagian Dataset*

Dataset penelitian dibagi menjadi 80% data *training* dan 20% data *testing*. Pembagian ini bertujuan agar model dapat mempelajari pola dari data *training*, kemudian dievaluasi menggunakan data *testing* yang belum pernah digunakan selama proses pelatihan. Hasil pembagian dataset ditunjukkan pada Tabel 2.

Tabel 2. Pembagian Dataset

Keterangan	Jumlah Data
Data Training	166
Data Testing	42
Total Dataset	208

Sebanyak 166 data *training* digunakan untuk membangun model *Random Forest*, sedangkan 42 data *testing* digunakan untuk mengevaluasi kemampuan model dalam memprediksi waktu tunggu pada data yang belum pernah dipelajari sebelumnya.

d. *Pelatihan Model Random Forest*

Pelatihan model dilakukan menggunakan algoritma *Random Forest Regressor* dengan parameter *n_estimators* = 200, *max_depth* = 5, *min_samples_split* = 4, dan *random_state* = 42. Parameter tersebut digunakan untuk menentukan jumlah *decision tree*, mengendalikan kompleksitas model, serta menjaga konsistensi hasil pelatihan.

Setelah parameter ditetapkan, model dilatih menggunakan data *training* melalui fungsi *model.fit()*. Model yang telah dilatih kemudian digunakan untuk menghasilkan prediksi terhadap data *testing* menggunakan fungsi *predict()*. Implementasi konfigurasi parameter, proses pelatihan, dan prediksi model ditunjukkan pada Gambar 3.

```

model = RandomForestRegressor(
    n_estimators=200,
    max_depth=5,
    min_samples_split=4,
    random_state=42
)
model.fit(X_train, y_train)
y_pred = model.predict(X_test)
print("-> Model selesai dilatih.\n")

```

Gambar 3. Implementasi Pelatihan Model *Random Forest*

Model yang telah dilatih selanjutnya digunakan pada tahap evaluasi untuk mengukur kemampuan prediksi terhadap data *testing* menggunakan metrik *R-Squared* (R^2) dan *Mean Absolute Error* (MAE)

e. Evaluasi Model


Evaluasi model dilakukan menggunakan data *testing* dengan membandingkan hasil prediksi terhadap nilai aktual menggunakan metrik *R-Squared* (R^2) dan *Mean Absolute Error* (MAE). Hasil evaluasi model ditunjukkan pada Tabel 3.

Tabel 3. Hasil Evaluasi Model	
Metrik Evaluasi	Nilai
R^2	0,9773
MAE (menit)	9,77

Berdasarkan hasil evaluasi, model memperoleh nilai R^2 sebesar 0,9773, yang menunjukkan bahwa model mampu menjelaskan sebagian besar variasi waktu tunggu berdasarkan data yang digunakan. Selain itu, nilai MAE sebesar 9,77 menit menunjukkan bahwa rata-rata selisih antara hasil prediksi dan nilai aktual relatif kecil. Hasil tersebut menunjukkan bahwa model *Random Forest* memiliki kemampuan yang sangat baik dalam memprediksi waktu tunggu pasien.

f. Visualisasi Hasil Prediksi


Visualisasi hasil prediksi dilakukan dengan membandingkan nilai waktu tunggu aktual terhadap nilai prediksi yang dihasilkan oleh model *Random Forest*.



Gambar 4. Perbandingan Nilai Aktual dan Prediksi Waktu Tunggu

Berdasarkan Gambar 4, sebagian besar titik berada di sekitar garis diagonal yang menunjukkan bahwa nilai prediksi mendekati nilai aktual. Hal tersebut menunjukkan bahwa model mampu mengenali pola hubungan antara variabel masukan dan waktu tunggu dengan baik. Meskipun terdapat beberapa titik yang menyimpang dari garis diagonal, pola sebaran secara keseluruhan tetap menunjukkan kesesuaian yang tinggi antara nilai aktual dan hasil prediksi. Hasil visualisasi ini mendukung nilai R^2 dan MAE yang diperoleh pada tahap evaluasi model.


Untuk mengetahui tingkat kontribusi masing-masing variabel terhadap hasil prediksi, dilakukan analisis *feature importance*. Hasil analisis ditunjukkan pada Gambar 5.

Gambar 5. *Feature Importance Model Random Forest*

Berdasarkan Gambar 5, variabel antrean sebelumnya memiliki nilai *feature importance* sebesar 0,8796, sedangkan jenis layanan memiliki nilai sebesar 0,1204. Hasil tersebut menunjukkan bahwa jumlah antrean sebelumnya merupakan faktor yang paling berpengaruh terhadap waktu tunggu pasien, sedangkan jenis layanan memberikan pengaruh yang lebih kecil terhadap hasil prediksi. Temuan ini sejalan dengan kondisi pelayanan, di mana semakin banyak pasien yang berada dalam antrean sebelumnya, maka waktu tunggu yang diperkirakan juga cenderung semakin lama.

Implementasi Sistem

Sistem antrean pasien berbasis *mobile* dibangun untuk memudahkan proses pendaftaran antrean serta memberikan informasi prediksi waktu tunggu kepada pasien. Model *Random Forest* yang telah dilatih diintegrasikan ke dalam sistem sehingga hasil prediksi dapat ditampilkan secara otomatis pada aplikasi.



Gambar 6. Halaman Pendaftaran Antrean

Halaman pendaftaran antrean digunakan oleh pasien untuk melakukan pendaftaran layanan secara digital dengan mengisi data yang diperlukan dan memilih poli tujuan. Setelah proses pendaftaran selesai, sistem akan menghasilkan nomor antrean yang digunakan pada proses pelayanan.



Gambar 7. Halaman Tiket Antrean

Halaman tiket antrean menampilkan informasi nomor antrean, poli tujuan, status antrean, serta estimasi waktu tunggu yang dihasilkan oleh model *Random Forest*. Informasi tersebut membantu pasien memperkirakan waktu pelayanan sehingga dapat mengurangi ketidakpastian selama menunggu antrean.

Pengujian Sistem

Pengujian sistem dilakukan menggunakan metode *Black Box Testing* untuk memastikan setiap fitur berfungsi sesuai dengan kebutuhan fungsional sistem. Hasil pengujian ditunjukkan pada Tabel 4.

Tabel 4. Hasil Pengujian Sistem

Fitur yang Diuji	Skenario Pengujian	Status
Pendaftaran antrean	Pasien mengisi data pendaftaran dan memilih poli tujuan melalui aplikasi mobile	Berhasil
Tiket antrean digital	Pasien membuka tiket antrean untuk melihat nomor antrean, poli tujuan, status antrean, dan estimasi waktu tunggu pelayanan	Berhasil
Cek Status Antrean	Pasien memasukkan data yang terdaftar untuk menampilkan kembali tiket antrean aktif	Berhasil
Pembatalan antrean	Pasien melakukan pembatalan terhadap tiket antrean yang telah dibuat	Berhasil

Berdasarkan hasil pengujian, seluruh fitur utama pada sistem berhasil dijalankan sesuai dengan skenario yang telah ditentukan. Fitur pendaftaran antrean, tiket antrean digital, cek status antrean, dan pembatalan antrean berfungsi dengan baik tanpa ditemukan kesalahan selama proses pengujian. Hasil tersebut menunjukkan bahwa sistem telah memenuhi kebutuhan fungsional dan siap digunakan untuk mendukung proses pelayanan antrean pasien.

KESIMPULAN

Penelitian ini berhasil membangun sistem antrean pasien berbasis *mobile* yang terintegrasi dengan algoritma *Random Forest* untuk memprediksi waktu tunggu pelayanan. Sistem yang dibangun memungkinkan pasien melakukan pendaftaran antrean secara digital sekaligus memperoleh informasi estimasi waktu tunggu melalui aplikasi *mobile*. Berdasarkan hasil evaluasi, model *Random Forest* memperoleh nilai R^2 sebesar 0,9773 dan *Mean Absolute Error* (MAE) sebesar 9,77 menit, yang menunjukkan kemampuan prediksi yang sangat baik. Analisis *feature importance* menunjukkan bahwa variabel antrean sebelumnya merupakan faktor yang paling berpengaruh terhadap hasil prediksi waktu tunggu. Selain itu, hasil pengujian menggunakan metode *Black Box Testing* menunjukkan bahwa seluruh fitur sistem berfungsi sesuai dengan kebutuhan fungsional. Dengan demikian, sistem yang dibangun mampu

memberikan informasi estimasi waktu tunggu secara efektif, membantu mengurangi ketidakpastian pasien, serta mendukung peningkatan kualitas pelayanan kesehatan.

REFERENSI

- Erawati, L., Sigiuro, B., & Diana, B. A. (2024). Analisis kualitas pelayanan kesehatan di Puskesmas Sumurgung Kecamatan Palang Kabupaten Tuban.
- Hariyoko, Y., Jehaut, Y. D., & Susiantoro, A. (2021). Efektivitas pelayanan kesehatan masyarakat oleh puskesmas di Kabupaten Manggarai. *Jurnal Administrasi Publik*, 17(2), 169–178.
- Rahmadini, N. A., & Rahman, A. (2024). Pengaruh lama waktu tunggu terhadap kepuasan pasien di Puskesmas Hikun Kabupaten Tabalong.
- Dewi, A., Eravianti, & Putri, D. K. (2020). Hubungan lama waktu tunggu pasien dengan kepuasan pasien di Puskesmas Lubuk Begalung.
- Taton, T. K., Saha, B., Islam, J., & Mostaque, S. K. (2025). A comprehensive approach to queue waiting time prediction using tree-based ensembles with data balancing and explainable AI.
- Roihan, A., Sunarya, P. A., & Rafika, A. S. (2020). Pemanfaatan machine learning dalam berbagai bidang: Review paper. *Jurnal Informatika*, 5, 75–82.
- Chazar, C., & Widhiaputra, B. E. (2020). Machine learning diagnosis kanker payudara menggunakan algoritma support vector machine. *Jurnal Teknologi Informasi*, 12(1), 67–80.
- Gupta, J., & Sharma, N. (2025). Assessment of patient waiting time and queue length using simulation model and machine learning techniques.
- Jimmy, V., & Siregar, B. (2025). Implementasi metode random forest dalam analisis prediksi Dogecoin. *Jurnal Sistem Informasi*, 14, 133–140.
- Sari, O. K., & Sari, A. A. (2025). Prediksi kunjungan wisatawan dengan random forest berbasis data historis dan eksternal.
- Himawan, D. B. (2025). Optimizing patient services through mobile-based queuing applications using Agile method.
- Guo, L. L., Tang, R., Wang, J. Y., Zheng, S., Zeng, Y., & Hou, J. (2025). Predicting waiting times for medical tasks in a pediatric hospital using machine learning: Comprehensive, retrospective, real-world study.
- Munggaran, R. P., & Nurmalasari, M. (2025). Predicting outpatient service waiting times with random forest algorithm. *Jurnal Teknologi Informasi*, 5, 35–40.
- Yusuf, P., et al. (2024). Patient flow control in emergency departments using simulation modeling and the random forest algorithm.
- Budiman, T. A., James, C. R., Howlett, N. C., & Wood, R. M. (2023). Near real-time prediction of urgent care hospital performance metrics using scalable random forest algorithm. *Health Systems*, 3, 100169.
- Aprilia, W., et al. (2021). Prediksi kemungkinan diabetes pada tahap awal menggunakan algoritma klasifikasi random forest. *Jurnal Ilmiah Teknologi*, 10, 163–171.