

Implementation Of The Random Forest Regression Algorithm For Estimating The Number Of Personnel At The Tangerang City Fire Department Call Center

Rahel Azzahra ¹⁾; Kahfi Heryandi Suradiradja ²⁾

^{1,2)} *Fakultas Ilmu Komputer, Universitas Pamulang*

Email: ¹⁾ rahelazzhira@gmail.com

How to Cite :

Azzahra, R., Suradiradja, K. H. (2026). Implementation of the Random Forest Regression Algorithm for Estimating the Number of Personnel at the Tangerang City Fire Department Call Center. Jurnal Media Computer Science, 5(4)

ARTICLE HISTORY

Received [10 Agustus 2026]

Revised [25 Oktober 2026]

Accepted [27 Oktober 2026]

KEYWORDS

Machine Learning, Personel Estimation, Random Forest Regression.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



ABSTRAK

Penelitian ini bertujuan menerapkan algoritme Random Forest Regression untuk mengestimasi jumlah personil yang dibutuhkan pada Call Center Pemadam Kebakaran Kota Tangerang berdasarkan data historis kejadian kebakaran tahun 2023–2025. Permasalahan penelitian berfokus pada kebutuhan estimasi personil yang cepat, tepat, dan berbasis data sebagai pendukung pengambilan keputusan petugas. Metode penelitian menggunakan Cross-Industry Standard Process for Data Mining (CRISP-DM) yang meliputi Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, dan Understanding. Variabel yang digunakan meliputi tahun, jam kejadian, kecamatan, jenis objek, tingkat kebakaran, cuaca, jumlah armada, dan waktu respons, dengan jumlah personil sebagai variabel target. Penelitian membandingkan Random Forest Regression dengan Linear Regression menggunakan metrik MAE, MSE, RMSE, dan R^2 . Hasil pengujian menunjukkan Random Forest Regression menghasilkan MAE sebesar 1,976, MSE sebesar 6,085, RMSE sebesar 2,467, dan R^2 sebesar 0,953, sehingga memiliki kinerja lebih baik dibandingkan Linear Regression. Model kemudian diimplementasikan pada aplikasi web berbasis Flask sebagai alat bantu operasional bagi petugas terkait.

ABSTRACT

This study aims to apply the Random Forest Regression algorithm to estimate the number of personnel required for the Tangerang City Fire Department Call Center, based on historical fire incident data from 2023 to 2025. The research addresses the need for rapid, accurate, and data-driven personnel estimation to support decision-making by personnel. The study employs the Cross-Industry Standard Process for Data Mining (CRISP-DM) methodology, comprising Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, and Understanding. The variables utilized include year, time of incident, district, object type, fire severity level, weather, fleet size, and response time, with the number of personnel serving as the target variable. The study compares Random Forest Regression with Linear Regression using MAE, MSE, RMSE, and R^2 metrics. Test results indicate that Random Forest Regression achieved an MAE of 1.976, MSE of 6.085, RMSE of 2.467, and R^2 of 0.953, demonstrating superior performance compared to Linear Regression. The model was subsequently implemented in a Flask-based web application to serve as an operational tool for relevant personnel.

PENDAHULUAN

Kebakaran merupakan salah satu keadaan darurat perkotaan yang menuntut koordinasi cepat antara penerimaan laporan, verifikasi informasi, penentuan sumber daya, dan pengerahan petugas. Kota Tangerang memiliki karakter wilayah perkotaan yang padat, aktivitas industri yang tinggi, serta keterhubungan langsung dengan kawasan metropolitan Jabodetabek. Kondisi tersebut membuat beban layanan pemadam kebakaran tidak hanya ditentukan oleh banyaknya kejadian, tetapi juga oleh variasi lokasi, objek yang terbakar, tingkat keparahan, kondisi cuaca, jumlah armada yang tersedia, dan kecepatan respons. Dalam rantai pelayanan tersebut, call center berfungsi sebagai titik awal pengambilan keputusan karena informasi pertama dari masyarakat diterjemahkan menjadi rekomendasi operasional bagi unit pemadam yang akan bergerak ke lokasi.

Permasalahan utama muncul ketika kebutuhan personil masih ditentukan tanpa dukungan model prediktif yang secara konsisten memanfaatkan pola historis. Kekurangan personil dapat memperpanjang waktu penanganan dan meningkatkan risiko keselamatan, sedangkan pengerahan personil secara berlebihan dapat menurunkan efisiensi sumber daya. Muhammad et al. (2025) menegaskan bahwa kecukupan personil merupakan komponen penting dalam penyelenggaraan layanan pemadam kebakaran karena berhubungan langsung dengan efektivitas operasi. Pada konteks layanan darurat berbasis panggilan, evaluasi layanan call center juga menempatkan kecepatan dan ketepatan respons sebagai elemen penting dalam kualitas pelayanan publik (Kabupaten, 2024). Oleh karena itu, kebutuhan personil perlu diperkirakan berdasarkan karakteristik kejadian, bukan hanya berdasarkan kebiasaan operasional atau penilaian subjektif.

Perkembangan Machine Learning menyediakan pendekatan yang memungkinkan data historis dipelajari untuk menghasilkan estimasi numerik. Syahreza et al. (2024) menunjukkan bahwa model prediktif dapat dibandingkan berdasarkan kemampuan menangkap pola data dan menghasilkan kesalahan yang rendah. Linear Regression memiliki keunggulan berupa struktur sederhana dan interpretasi yang mudah, tetapi kinerjanya sangat dipengaruhi oleh asumsi hubungan linear antara fitur dan target. Sebaliknya, Random Forest Regression menggabungkan banyak decision tree sehingga mampu merepresentasikan hubungan non-linear, interaksi antarfitur, dan variasi data yang lebih kompleks. Karakteristik ini relevan dengan data kejadian kebakaran yang heterogen karena hubungan antara tingkat kebakaran, jenis objek, armada, waktu respons, dan kebutuhan personil tidak selalu mengikuti pola linear tunggal.

Sejumlah penelitian terdahulu mendukung penggunaan Random Forest pada berbagai masalah prediksi. Tantyoko et al. (2023) menggunakan Random Forest dan feature selection untuk prediksi potensi gempa bumi dan menunjukkan bahwa pemilihan fitur dapat meningkatkan performa. Saputri dan Rosnita (2025) melaporkan kinerja Random Forest yang baik untuk prediksi performa akademik, sedangkan Urrochman dan Hizham (2025) membandingkan Random Forest Regression dengan Support Vector Regression pada prediksi harga saham dan memperoleh R^2 yang sangat tinggi pada Random Forest. Pada kasus produksi dan penjualan, model Random Forest juga dilaporkan mampu memberikan akurasi prediksi yang baik (Produk, 2024; Science et al., 2025). Temuan-temuan tersebut memperlihatkan konsistensi kemampuan Random Forest pada data numerik dengan hubungan antarvariabel yang kompleks.

LANDASAN TEORI

Estimasi Kebutuhan Personil

Estimasi merupakan proses memperkirakan suatu nilai berdasarkan data, informasi, atau kondisi yang tersedia untuk memperoleh nilai yang mendekati keadaan sebenarnya. Dalam statistik dan Machine Learning, estimasi memanfaatkan data historis melalui model matematis atau algoritme tertentu sebagai dasar perencanaan dan pengambilan keputusan. Rokim (2025) menjelaskan bahwa hasil estimasi dapat digunakan untuk mendukung pengalokasian sumber daya secara efektif dan efisien, dengan tingkat akurasi yang sangat dipengaruhi oleh kualitas data serta metode yang digunakan.

Dalam operasional pemadam kebakaran, estimasi diperlukan untuk menentukan jumlah personil yang akan dikerahkan berdasarkan karakteristik kejadian, seperti tingkat kebakaran, jenis objek, kondisi lokasi, tingkat risiko, serta kebutuhan operasional. Jumlah personil yang tidak sesuai dapat memengaruhi efektivitas penanganan; kekurangan personil berpotensi memperlambat proses penanganan dan meningkatkan risiko keselamatan, sedangkan jumlah personil yang berlebihan dapat menyebabkan penggunaan sumber daya menjadi kurang efisien (Muhammad et al., 2025).

Call center pemadam kebakaran berperan sebagai pusat penerimaan informasi dan titik kontak awal antara masyarakat dengan petugas layanan kedaruratan. Pengelolaan personil call center mencakup workforce management, scheduling, dan performance monitoring untuk memastikan ketersediaan tenaga kerja dan kualitas pelayanan (Kabupaten, 2024). Pada Dinas Pemadam Kebakaran Kota Tangerang, informasi yang diterima melalui call center menjadi dasar dalam menentukan kebutuhan personil dan armada yang diberangkatkan ke lokasi kejadian. Oleh karena itu, estimasi jumlah personil yang tepat menjadi bagian penting dalam mendukung respons penanganan kebakaran yang efektif, efisien, dan berbasis data.

Machine Learning

Machine Learning merupakan cabang dari Artificial Intelligence yang memungkinkan sistem komputer mempelajari pola dari data untuk menghasilkan prediksi atau keputusan tanpa harus diprogram secara khusus untuk setiap tugas. Proses pembelajaran dilakukan dengan memanfaatkan data historis melalui algoritme tertentu. Secara umum, Machine Learning terdiri atas supervised learning, unsupervised learning, dan reinforcement learning. Supervised learning digunakan pada data yang memiliki label atau target, unsupervised learning digunakan untuk menemukan pola pada data tanpa label, sedangkan reinforcement learning mempelajari tindakan melalui interaksi dengan lingkungan untuk memperoleh hasil yang optimal (Syahreza et al., 2024). Dalam penelitian ini, pendekatan supervised learning digunakan karena model dibangun untuk mengestimasi jumlah personil berdasarkan data historis dengan variabel target yang telah diketahui.

Linear Regression dan Random Forest Regression

Linear Regression memodelkan target sebagai kombinasi linear dari satu atau lebih variabel input. Kelebihannya adalah sederhana, cepat, dan mudah digunakan sebagai baseline. Namun, apabila hubungan antarvariabel bersifat non-linear atau terdapat interaksi kompleks, kemampuan model dapat menurun. Wijaya (2023) membandingkan beberapa metode regresi pada prediksi harga dan menunjukkan bahwa karakter data berperan dalam menentukan model yang paling sesuai. Dalam penelitian ini, Linear Regression tidak ditempatkan sebagai model akhir secara apriori, tetapi sebagai pembanding untuk mengukur manfaat penggunaan model ensemble yang lebih fleksibel.

Random Forest Regression merupakan metode ensemble yang membangun sejumlah decision tree dari sampel bootstrap dan subset fitur yang dipilih secara acak. Prediksi akhir diperoleh dengan merata-ratakan keluaran seluruh pohon. Mekanisme agregasi ini menurunkan varians dibandingkan penggunaan satu decision tree dan memungkinkan model menangkap interaksi non-linear tanpa mensyaratkan bentuk distribusi tertentu. Pada naskah sumber, prediksi Random Forest dapat dinyatakan sebagai rata-rata prediksi B pohon, yaitu $\hat{f}(x) = (1/B) \sum f_b(x)$. Keunggulan tersebut menjadi alasan utama pemilihan Random Forest Regression untuk data kebakaran yang memiliki variasi kategori kejadian, lokasi, kondisi cuaca, armada, dan waktu respons.

Metrik Evaluasi Model Regresi

Evaluasi model menggunakan *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan coefficient of determination (R^2). MAE menggambarkan rata-rata selisih absolut antara nilai aktual dan prediksi sehingga mudah ditafsirkan dalam satuan personil. MSE

mengkuadratkan kesalahan sehingga memberi penalti lebih besar terhadap prediksi yang jauh dari nilai aktual, sedangkan RMSE mengembalikan besaran kesalahan ke satuan target. R^2 menunjukkan proporsi variasi target yang dapat dijelaskan model. Chicco et al. (2021) menekankan pentingnya R^2 dalam evaluasi regresi, tetapi interpretasi yang kuat tetap memerlukan pembacaan bersama metrik kesalahan. Karena itu, model yang baik pada penelitian ini diharapkan memiliki MAE, MSE, dan RMSE lebih rendah serta R^2 lebih tinggi.

Aplikasi Pendukung

Pengembangan model dan aplikasi estimasi jumlah personil pada penelitian ini didukung oleh beberapa perangkat lunak utama, yaitu Python, Flask, Google Colab, dan Visual Studio Code. Python digunakan sebagai bahasa pemrograman utama karena mendukung pengolahan data dan Machine Learning melalui pustaka seperti NumPy, Pandas, Scikit-learn, dan Matplotlib (Alfarizi & Al-farish, 2023). Model yang telah dibangun kemudian diintegrasikan ke dalam aplikasi berbasis web menggunakan Flask, yaitu micro web framework berbasis Python yang ringan dan fleksibel untuk pengembangan aplikasi (Sistem & Helpdesk, 2022).

Proses pengolahan data dan pelatihan model dilakukan dengan bantuan Google Colab, yaitu lingkungan komputasi berbasis cloud yang memungkinkan eksekusi notebook Python secara daring serta mendukung kebutuhan analisis data dan Machine Learning (Octarina et al., 2025). Sementara itu, Visual Studio Code digunakan sebagai source code editor untuk menulis, menyunting, menjalankan, dan melakukan debugging kode program selama proses pengembangan aplikasi. Editor ini mendukung berbagai bahasa pemrograman dan dapat diperluas melalui berbagai ekstensi sesuai kebutuhan pengembangan (Development & One, 2020). Kombinasi perangkat tersebut mendukung proses pengolahan data, pembangunan model, hingga implementasi sistem estimasi secara terintegrasi.

Metode Pengembangan Sistem

Penelitian ini menerapkan metode Prototyping sebagai pendekatan pengembangan sistem karena memungkinkan pembuatan rancangan awal (prototype) yang dapat dievaluasi oleh pengguna sebelum sistem dikembangkan secara penuh. Melalui proses evaluasi dan perbaikan secara berulang, metode ini membantu menghasilkan sistem yang lebih sesuai dengan kebutuhan pengguna. Prototype digunakan untuk memberikan gambaran awal mengenai fungsi, tampilan, dan alur kerja sistem sehingga pengguna dapat memberikan masukan sejak tahap perancangan (M. I. Saputri et al., 2024; J. Informatika et al., 2022).

Tahapan Prototyping dimulai dengan analisis kebutuhan melalui wawancara, observasi, dan studi dokumentasi sebagai dasar penentuan fungsi serta fitur sistem (Kustanto et al., 2025). Selanjutnya dibuat prototype dalam bentuk rancangan antarmuka atau aplikasi awal yang kemudian dievaluasi oleh pengguna. Apabila masih terdapat ketidaksesuaian, dilakukan perbaikan hingga rancangan memenuhi kebutuhan yang ditetapkan (M. Informatika & Digital, 2024). Setelah prototype disetujui, proses dilanjutkan dengan pengkodean untuk mengimplementasikan rancangan menjadi aplikasi yang dapat dijalankan (Lubis et al., 2025). Sistem yang telah dibangun kemudian diuji untuk memastikan fungsi berjalan sesuai kebutuhan dan mengidentifikasi kemungkinan kesalahan sebelum digunakan oleh pengguna akhir. Tahap terakhir adalah evaluasi, perbaikan, serta implementasi sistem pada lingkungan operasional sehingga aplikasi dapat digunakan untuk mendukung kegiatan pengguna (Puteri et al., 2022).

Unified Modeling Language (UML)

Unified Modeling Language (UML) merupakan bahasa pemodelan visual yang digunakan untuk menggambarkan struktur, proses, dan interaksi dalam sistem perangkat lunak secara terstruktur sehingga mempermudah proses analisis, perancangan, serta komunikasi antara pengembang dan pengguna (Management & Educators, 2022). Dalam penelitian ini, pemodelan sistem menggunakan tiga diagram utama, yaitu Use Case Diagram, Activity Diagram, dan Sequence

Diagram. Use Case Diagram digunakan untuk menggambarkan kebutuhan fungsional sistem, aktor yang terlibat, serta hubungan antara pengguna dan fungsi yang tersedia dalam sistem (Management & Educators, 2022). Activity Diagram digunakan untuk memvisualisasikan alur aktivitas, keputusan, dan proses yang terjadi pada sistem sehingga urutan kerja dapat dipahami secara lebih jelas (Bangsa et al., 2025). Sementara itu, Sequence Diagram menggambarkan urutan interaksi dan pertukaran pesan antarobjek dalam sistem dari awal proses hingga menghasilkan keluaran yang diharapkan, serta dapat digunakan sebagai acuan dalam penyusunan skenario pengujian sistem (Mahardika & Abdillah, 2024). Ketiga diagram tersebut digunakan untuk memperjelas rancangan sistem estimasi jumlah personil sebelum tahap implementasi aplikasi.


Teori Pengujian Sistem

Pengujian sistem merupakan tahapan untuk memastikan aplikasi yang dibangun telah berjalan sesuai kebutuhan pengguna dan spesifikasi yang ditetapkan. Proses ini digunakan untuk menemukan kesalahan, mengevaluasi kelayakan fungsi, serta menjamin kualitas perangkat lunak sebelum digunakan oleh pengguna akhir (Jamaliyah, 2022). Dalam penelitian ini, pengujian dilakukan menggunakan Black Box Testing dan White Box Testing. Black Box Testing berfokus pada pengujian fungsi sistem melalui pemberian masukan dan pemeriksaan keluaran tanpa melihat struktur kode internal. Sementara itu, White Box Testing digunakan untuk memeriksa struktur internal program, termasuk logika, jalur eksekusi, percabangan, dan perulangan, sehingga seluruh proses pada aplikasi dapat dipastikan berjalan sesuai rancangan.

METODE PENELITIAN

Penelitian ini menggunakan metode CRISP-DM (Cross-Industry Standard Process for Data Mining), salah satu metodologi yang lazim dipakai dalam proses data mining maupun pengembangan model Machine Learning karena menyajikan tahapan kerja yang sistematis, mulai dari memahami permasalahan hingga menerapkan hasil model. Metodologi ini dipilih agar proses penelitian berjalan terstruktur dan model yang dihasilkan sesuai dengan tujuan penelitian (Gede et al., 2025).

Tahapan CRISP-DM yang diterapkan disesuaikan dengan kebutuhan penelitian, meliputi Business Understanding, Data Understanding, Data Preparation, Modeling, Evaluation, dan Deployment. Alur penelitian secara keseluruhan ditampilkan pada Gambar 1.



Gambar 1. Alur Pengolahan Data Berbasis CRISP-DM Pada Penelitian

Tahapan dimulai dari business understanding untuk merumuskan kebutuhan operasional, yaitu tersedianya rekomendasi jumlah personil secara cepat dan berbasis data. Data understanding digunakan untuk memeriksa struktur atribut, tipe data, nilai kosong, data duplikat, statistik deskriptif, distribusi, dan korelasi. Data preparation mencakup pembersihan, penghapusan duplikasi, transformasi data, seleksi fitur, serta penyusunan data menjadi format numerik yang

dapat diproses algoritme. Tahap modeling membangun Linear Regression sebagai baseline dan Random Forest Regression sebagai model utama. Evaluation membandingkan model menggunakan MAE, MSE, RMSE, dan R^2 . Model terbaik kemudian diterapkan pada aplikasi sebagai tahap implementasi/deployment hasil penelitian.

Data yang dianalisis berupa data historis kejadian kebakaran Kota Tangerang periode 2023-2025. Data diperoleh dari sumber operasional instansi dan proses ekstraksi dibantu Python melalui BeautifulSoup dan Selenium. Fokus pengolahan diarahkan pada pemanfaatan atribut kejadian yang relevan untuk mengestimasi jumlah personil. Model dibangun menggunakan Python dan pustaka scikit-learn, sedangkan implementasi aplikasi menggunakan Flask. Pengembangan antarmuka mengikuti metode prototyping agar fungsi estimasi dapat diuji dari sisi alur penggunaan.

Sebelum pemodelan, dataset diperiksa untuk menemukan missing value dan data duplikat. Variabel kategorikal telah tersedia dalam bentuk numerik hasil pengkodean pada dataset yang digunakan, sehingga tidak diperlukan encoding tambahan pada tahap implementasi model. Feature selection menetapkan delapan fitur model akhir sebagaimana Tabel 2, dengan Jumlah Personil sebagai target. Dataset kemudian dibagi menjadi 70% data training dan 30% data testing. Data training digunakan untuk mempelajari pola, sedangkan data testing dipakai untuk mengukur performa pada data yang tidak dilibatkan dalam pelatihan. Ruang lingkup naskah juga menempatkan grid search cross-validation sebagai pendekatan optimasi parameter Random Forest, sementara hasil yang dilaporkan berfokus pada performa model akhir.


Analisis eksploratif menggunakan histogram untuk melihat distribusi jumlah personil dan heatmap untuk memahami hubungan antarvariabel. Visualisasi tidak digunakan sebagai satu-satunya dasar pemilihan fitur, tetapi sebagai instrumen untuk membaca struktur data sebelum pemodelan. Selanjutnya Linear Regression dilatih sebagai baseline, sedangkan Random Forest Regression dilatih untuk menangkap pola non-linear. Prediksi kedua model dievaluasi menggunakan metrik yang sama sehingga perbandingan bersifat konsisten.

Tahap pengembangan sistem dilakukan setelah model terbaik teridentifikasi. Model Random Forest Regression disimpan dalam file model.pkl dan dimuat oleh aplikasi Flask. Aplikasi menerima parameter kejadian dari pengguna, menyiapkan input sesuai struktur fitur model, lalu menjalankan fungsi prediksi. Untuk melengkapi fitur Jumlah Armada dan Waktu Respons ketika input utama berasal dari parameter laporan, aplikasi memanfaatkan data historis dengan mekanisme pencarian kecocokan bertingkat. Apabila kombinasi identik tidak tersedia, sistem mencari histori yang mirip dengan mengurangi sebagian parameter secara bertahap; jika kecocokan tetap tidak ditemukan, nilai rata-rata historis digunakan. Hasil estimasi kemudian ditampilkan bersama detail kejadian dan rekomendasi pendukung.

HASIL DAN PEMBAHASAN


Hasil

Eksplorasi dataEksplorasi dataset menunjukkan bahwa jumlah personil memiliki sebaran yang tidak terkonsentrasi pada satu nilai tunggal. Histogram memperlihatkan frekuensi yang relatif tinggi pada rentang personil rendah hingga menengah dan frekuensi yang menurun pada kebutuhan personil yang lebih besar. Pola ini menunjukkan adanya variasi kebutuhan sumber daya antar kejadian. Variasi tersebut penting karena model tidak hanya harus memprediksi kondisi rutin, tetapi juga tetap sensitif terhadap kejadian yang membutuhkan pengerahan personil lebih besar.



Gambar 2. Distribusi Jumlah Personil pada Dataset Historis

Heatmap korelasi memperlihatkan bahwa hubungan antarvariabel numerik tidak seragam. Beberapa fitur menunjukkan hubungan yang lebih kuat dengan Jumlah Personil dibandingkan fitur lainnya, terutama fitur yang secara operasional berkaitan dengan tingkat kejadian dan sumber daya. Namun, tidak seluruh hubungan tampak linear kuat. Kondisi ini menjadi indikasi awal bahwa model yang mampu menangkap interaksi non-linear berpotensi memberikan hasil lebih baik dibandingkan model linear murni.



Gambar 3. Heatmap Korelasi Antarvariabel pada Dataset

Hasil evaluasi menunjukkan kedua model memiliki kemampuan prediktif yang tinggi, tetapi Random Forest Regression memberikan kesalahan yang lebih rendah pada seluruh metrik error dan R^2 yang lebih tinggi. Linear Regression menghasilkan MAE 2,683, MSE 10,144, RMSE 3,185, dan R^2 0,921. Random Forest Regression menghasilkan MAE 1,976, MSE 6,085, RMSE 2,467, dan R^2 0,953. Dengan MAE sekitar 1,976, rata-rata kesalahan absolut Random Forest berada pada kisaran dua personil, sedangkan Linear Regression berada pada kisaran hampir tiga personil.

Tabel 1. Perbandingan Hasil Evaluasi Model

Metrik	Linear Regression	Random Forest Regression	Interpretasi
MAE	2,683	1,976	RFR menurunkan rata-rata kesalahan absolut.
MSE	10,144	6,085	RFR memberi penalti kesalahan besar yang lebih rendah.

Metrik	Linear Regression	Random Forest Regression	Interpretasi
RMSE	3,185	2,467	Deviasi prediksi RFR lebih kecil.
R ²	0,921	0,953	RFR menjelaskan 95,3% variasi target.

Sumber: Data diolah 2026.

Secara relatif, penggunaan Random Forest Regression menurunkan MAE sekitar 26,35%, MSE sekitar 40,01%, dan RMSE sekitar 22,54% dibandingkan Linear Regression. Nilai R² meningkat secara absolut sebesar 0,032, dari 0,921 menjadi 0,953. Perbedaan tersebut menunjukkan bahwa keunggulan Random Forest bukan hanya terlihat pada satu metrik, tetapi konsisten pada ukuran kesalahan maupun kemampuan menjelaskan variasi target. Karena itu, model ini dipilih sebagai model akhir untuk diintegrasikan ke prototipe aplikasi.

Implementasi Sistem

Aplikasi web dibangun untuk menerjemahkan hasil pemodelan menjadi fungsi yang dapat digunakan petugas. Halaman estimasi menyediakan pilihan Tahun, Jam Kejadian, Kecamatan, Jenis Objek, Tingkat Kebakaran, dan Cuaca. Input tersebut selanjutnya dipadukan dengan informasi historis untuk membentuk delapan fitur yang diperlukan model. Desain antarmuka dibuat ringkas agar petugas dapat memilih parameter kejadian tanpa harus berinteraksi langsung dengan kode Machine Learning. Pemisahan antara antarmuka, controller Flask, data historis, dan model prediktif juga memudahkan pemutakhiran model pada pengembangan berikutnya.

Gambar 4. Implementasi Antarmuka Form Estimasi Personil

Pada skenario pengujian yang ditampilkan dalam naskah sumber, sistem menghasilkan estimasi 18 personil. Keluaran dilengkapi rekomendasi tiga unit armada, estimasi waktu respons 15 menit, dan informasi sumber histori berupa "Histori Mirip (Tanpa Tahun, Jam, Cuaca)". Penyajian sumber histori memberi konteks terhadap pembentukan fitur tambahan dan membantu pengguna memahami bahwa estimasi tidak muncul sebagai angka tanpa dasar. Mekanisme fallback juga menjaga sistem tetap dapat menghasilkan prediksi ketika kombinasi parameter tertentu tidak ditemukan secara identik pada data historis.

HASIL ESTIMASI

18

Personil

Detail Kejadian

Jam: Malam
Kecamatan: Batuceper
Jenis Objek: Gudang
Tingkat Kebakaran: Ringan
Cuaca: Berangin

Rekomendasi Sistem

Jumlah Armada: 3 Unit
Estimasi Waktu Respon: 15 Menit
Sumber Histori:
Histori Mirip (Tanpa Tahun, Jam, Cuaca)

Kebutuhan Personil Tinggi

Gambar 5. Contoh Hasil Estimasi Jumlah Personil dan Rekomendasi Sistem

Pengujian Fungsional

Black Box Testing digunakan untuk memastikan fungsi utama aplikasi berjalan sesuai kebutuhan pengguna. Pengujian mencakup akses halaman login, proses autentikasi, tampilan form estimasi, penerimaan parameter, perhitungan estimasi, tampilan hasil, dan logout. Seluruh skenario yang dilaporkan pada naskah sumber berstatus valid. Hasil tersebut menunjukkan bahwa integrasi antara antarmuka, proses validasi, pemanggilan model, dan penyajian keluaran dapat berjalan pada skenario uji yang dirancang.

Tabel 2. Ringkasan Hasil Black Box Testing

No.	Skenario	Hasil Utama	Status
1	Menampilkan halaman login	Form username dan password tampil.	Valid
2	Autentikasi login	Kredensial divalidasi dan pengguna diarahkan ke dashboard.	Valid
3	Menampilkan form estimasi	Form estimasi tampil lengkap.	Valid
4	Memilih parameter kejadian	Seluruh parameter diterima sistem.	Valid
5	Menjalankan estimasi	Perhitungan diproses tanpa kesalahan.	Valid
6	Menampilkan hasil	Estimasi 18 personil, 3 armada, respons 15 menit, dan sumber histori tampil.	Valid
7	Logout	Sesi dihapus dan pengguna kembali ke halaman login.	Valid

Sumber: Data diolah 2026.

Selain pengujian fungsional, naskah sumber menerapkan White Box Testing dengan pendekatan cyclomatic complexity terhadap alur program. Pendekatan ini ditujukan untuk memastikan jalur logika pada route aplikasi dapat diperiksa secara internal. Potongan kode yang diuji memuat penerimaan input melalui metode POST, penyusunan data fitur, pemanggilan model.predict(), dan pengembalian hasil ke template. Dokumentasi yang tersedia tidak menampilkan nilai akhir cyclomatic complexity secara eksplisit, sehingga artikel ini tidak menambahkan nilai numerik yang tidak didukung sumber.

Pembahasan

Keunggulan Random Forest Regression dapat dijelaskan dari struktur data dan karakter operasional masalah. Kebutuhan personil tidak hanya dipengaruhi oleh satu faktor, tetapi oleh kombinasi kondisi yang saling berinteraksi. Tingkat kebakaran yang sama pada objek berbeda dapat memerlukan komposisi petugas berbeda; lokasi dan waktu kejadian dapat berkaitan dengan pola respons; jumlah armada serta waktu respons juga merepresentasikan intensitas penanganan. Linear Regression berusaha merangkum hubungan tersebut dalam bentuk kombinasi linear, sedangkan Random Forest membentuk banyak batas keputusan lokal melalui decision tree. Kemampuan membagi ruang fitur ke dalam sejumlah pola lokal membuat model ensemble lebih fleksibel menghadapi hubungan yang tidak linear dan heterogen.

Penurunan MSE sebesar sekitar 40,01% memiliki arti penting karena MSE memberikan penalti besar pada kesalahan prediksi ekstrem. Dalam konteks layanan pemadam kebakaran, kesalahan ekstrem lebih kritis daripada kesalahan kecil karena underestimation pada kejadian besar dapat menyebabkan pengerahan awal yang tidak memadai, sedangkan overestimation yang besar dapat mengurangi efisiensi sumber daya. Penurunan RMSE sekitar 22,54% memperkuat temuan bahwa Random Forest lebih mampu menekan deviasi prediksi secara keseluruhan. Pada saat yang sama, kenaikan R^2 menjadi 0,953 menunjukkan bahwa sebagian besar variasi jumlah personil pada data uji dapat dijelaskan oleh kombinasi fitur yang digunakan.

Temuan tersebut sejalan dengan pola penelitian terdahulu. Tantyoko et al. (2023) memperlihatkan bahwa Random Forest efektif pada data kebencanaan dengan banyak variabel dan dapat memperoleh manfaat dari pengelolaan fitur. Urrochman dan Hizham (2025) juga menunjukkan bahwa Random Forest Regression dapat mengungguli model pembandingan pada prediksi numerik yang kompleks. Sementara itu, hasil penelitian ini memberi konteks aplikasi baru pada manajemen personil layanan darurat. Perbedaan konteks tersebut penting karena target bukan harga, produksi, atau indeks, melainkan sumber daya manusia yang akan digunakan dalam operasi keselamatan publik. Dengan demikian, konsekuensi kesalahan prediksi perlu dibaca tidak hanya dari sisi statistik, tetapi juga dari sisi kesiapan operasional.

R^2 yang tinggi tidak berarti model telah menyelesaikan seluruh persoalan alokasi personil. Sekitar 4,7% variasi target masih tidak dijelaskan oleh model. Variasi tersebut dapat berasal dari faktor yang belum tersedia pada dataset, seperti kepadatan lalu lintas menuju lokasi, ketersediaan personil aktual per shift, luas area terdampak, keberadaan bahan berbahaya, akses jalan, kepadatan bangunan, kondisi sumber air, atau kebutuhan dukungan lintas instansi. Karena itu, keluaran sistem lebih tepat diposisikan sebagai rekomendasi pendukung keputusan daripada pengganti penilaian operasional petugas. Model memberi baseline kuantitatif yang konsisten, sedangkan keputusan akhir tetap memerlukan verifikasi terhadap kondisi lapangan.

Mekanisme pencarian histori bertingkat pada aplikasi merupakan aspek praktis yang menambah ketahanan sistem terhadap kombinasi input yang tidak pernah muncul secara identik. Namun, mekanisme ini juga menghadirkan konsekuensi metodologis. Ketika Jumlah Armada dan Waktu Respons diisi berdasarkan rata-rata histori yang semakin longgar tingkat kecocokannya, ketidakpastian input dapat meningkat. Karena kedua fitur tersebut digunakan oleh model, kualitas fallback dapat memengaruhi keluaran prediksi. Pengembangan selanjutnya perlu mencatat tingkat kecocokan histori dan, bila memungkinkan, menampilkan indikator keyakinan atau rentang estimasi agar pengguna mengetahui seberapa kuat dukungan data terhadap rekomendasi yang diberikan.

Dari sisi rekayasa perangkat lunak, integrasi model melalui Flask memberi jalur yang sederhana dari input petugas menuju prediksi. Flask sesuai untuk prototipe karena ringan dan mudah dihubungkan dengan model yang disimpan melalui pickle. Namun, implementasi operasional skala instansi memerlukan kontrol tambahan, seperti autentikasi yang lebih kuat, pencatatan audit, validasi tipe dan rentang input, pengelolaan versi model, pengamanan file model, serta mekanisme rollback jika pembaruan model menurunkan performa. Pengujian Black Box yang seluruhnya valid menunjukkan fungsi dasar berjalan, tetapi belum cukup untuk menyimpulkan kesiapan produksi tanpa pengujian keamanan, beban, reliabilitas, dan penerimaan pengguna.

Kebaruan logis penelitian terletak pada penyatuan tiga lapisan yang sebelumnya terpisah dalam studi-studi rujukan: penggunaan data historis kejadian kebakaran sebagai dasar estimasi personil, evaluasi komparatif model regresi untuk memastikan pilihan algoritme berbasis metrik, dan penerjemahan model terbaik ke prototipe aplikasi yang mendukung proses call center. Dengan struktur tersebut, hasil penelitian tidak berhenti pada nilai akurasi, tetapi menunjukkan bagaimana model dapat masuk ke alur keputusan petugas. Implementasi ini memberi dasar bagi pengembangan sistem yang lebih terintegrasi dengan basis data operasional Dinas Pemadam Kebakaran Kota Tangerang.

KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan hasil penelitian, dapat ditarik kesimpulan sebagai berikut:

1. Penelitian ini berhasil menerapkan algoritme Random Forest Regression untuk memperkirakan jumlah personel yang dibutuhkan berdasarkan data kejadian kebakaran historis di Kota Tangerang. Hasil evaluasi menunjukkan kinerja yang sangat baik, dengan Mean Squared Error (MSE) sebesar 6,40, Mean Absolute Error (MAE) sebesar 1,98, Root Mean Squared Error (RMSE) sebesar 2,53, dan R^2 Score sebesar 0,9503. Nilai-nilai tersebut menunjukkan model mampu menjelaskan 95,03% variasi data personel, sehingga menghasilkan tingkat akurasi prediksi yang tinggi.
2. Perbandingan antara algoritme Random Forest Regression dan Linear Regression menunjukkan bahwa Random Forest Regression berkinerja lebih baik, dibuktikan dengan kesalahan prediksi yang lebih rendah dan skor R^2 yang lebih tinggi, sehingga algoritme ini lebih sesuai dipakai memperkirakan kebutuhan personel di Call Center Dinas Pemadam Kebakaran Kota Tangerang.

Saran

Berdasarkan keterbatasan penelitian, saran untuk pengembangan sistem selanjutnya adalah sebagai berikut:

Pengembangan selanjutnya disarankan menggunakan dataset dengan rentang waktu lebih panjang dan volume lebih besar, menambahkan variabel operasional yang lebih representatif, serta membandingkan *Random Forest Regression* dengan *XGBoost Regression*, *Gradient Boosting Regression*, dan *Support Vector Regression*. Integrasi langsung dengan basis data operasional Dinas Pemadam Kebakaran Kota Tangerang dapat mengurangi input manual dan memperbarui model secara berkala. Dari sisi aplikasi, fitur riwayat prediksi, visualisasi tren, dashboard pemantauan, akses multi-pengguna, pencatatan audit, dan indikator ketidakpastian prediksi dapat ditambahkan. Evaluasi lanjutan juga perlu memasukkan validasi temporal, cross-validation yang terdokumentasi, analisis feature importance, pengujian performa sistem, dan User Acceptance Testing agar manfaat model dapat dinilai tidak hanya dari akurasi statistik, tetapi juga dari ketepatan keputusan dan efisiensi layanan.

DAFTAR PUSTAKA

- Alfarizi, M. R., & Al-Farish, M. Z. (2023). Penggunaan Python sebagai bahasa pemrograman untuk machine learning dan deep learning, 2, 1-6.
- Bangsa, S. A., Aprilyani, F., & Febriyanti, V. (2025). Pengembangan sistem informasi penjualan berbasis web, 14(2), 51-59.
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. <https://doi.org/10.7717/peerj-cs.623>
- Development, I., & One, E. (2020). Implementasi Pemrograman Python Menggunakan Visual Studio Code. 2, 1-9.

- Informatika, M., & Digital, U. T. (2024). Jurnal Informatika Terpadu. 10(1), 1–10.
- Gede, I. M., Baraja, A., & Gede, I. K. (2025). Implementasi algoritme Random Forest Regression dalam sistem prediksi harga rumah di Jabodetabek, 4, 27-38.
- Jamaliyah, I. (2022). Perbandingan metode testing, 8(2), 105-114.
- Kabupaten, D. I. (2024). Evaluation of emergency call services: Implementation of Call Center 112. Jurnal Media Administrasi Terapan, 5(1), 45-56.
- Kustanto, P., Ramadhan, B. K., & Noe, A. (2025). Penerapan metode prototype dalam perancangan media pembelajaran interaktif, 5(1), 83-94.
- Lubis, A. F., Yusar, M. R., Wijaya, D. S., Nuaridito, M. F., & Prambodo, Y. L. (2025). Pengelolaan Stok Bahan Baku Berbasis Web Menggunakan Metode Prototyping. 9(2), 299–307. <https://doi.org/10.52362/jisicom.v9i2.2149>
- Mahardika, F., & Abdillah, M. L. (2024). Design of Unified Modeling Language Information System for Motorcycle Unit Selling and Buying Transactions using the Waterfall Method.
- Management, I., & Educators, F. O. R. (2022). Penerapan . Unified Modeling Language .(UML) Dalam Membangun Sistem Pengenalan UMKM (Studi Kasus Rafa Laundry). 7(1), 21–30.
- Mangun, S. S. (2025). Prediksi kebakaran hutan Ibu Kota Nusantara menggunakan data MODIS dan algoritme machine learning, 7(2), 1-10. <https://doi.org/10.37905/jji.v1i1.30926>
- Muhammad, H., Mubarak, R., Darmawan, I., & Centia, S. (2025). Analisis penyelenggaraan pemberdayaan oleh satuan pemadam kebakaran Kabupaten Majalengka tahun 2023, 7, 179-192.
- Octarina, S., Puspita, F. M., Yuliza, E., & Meeting, G. (2025). Jurnal Pepadu Jurnal Pepadu. 6(1), 56–66.
- Produk, P. (2024). Implementasi metode Random Forest untuk memprediksi penjualan produk, 7, 591-600. <https://doi.org/10.37600/tekinkom.v7i2.1510>
- Puteri, A. N., Zakiyabarsi, F., & Priambodo, D. F. (2022). Metode Prototype Pada Sistem Informasi Manajemen Tugas Akhir Mahasiswa Berbasis Website. 10(1).
- Rokim, A. (2025). Data mining untuk estimasi waktu produksi dan pengiriman komponen prefab berdasarkan riwayat, 3(7).
- Saputri, M. I., Handayani, V. R., Rahmawati, E., & Kesuma, C. (2024). Penerapan metode prototype dalam perancangan sistem informasi service pada Bengkel Sido Motor berbasis website, 4(2), 39-47.
- Saputri, R. A., & Rosnita, L. (2025). A Random Forest-based predictive model for student academic performance: A case study in Indonesian public high schools, 9(3), 1042-1049.
- Science, C., Program, S., Info, A., Palm, O., & Prediction, P. (2025). Random Forest Regression algorithm in predicting coconut plantation yields, 7(3), 728-739.
- Sistem, A., & Helpdesk, I. (2022). Implementasi Flask framework pada pembangunan aplikasi sistem informasi helpdesk (SIH), 7, 858-868.
- Syahreza, A., Ningrum, N. K., & Syahrazy, M. A. (2024). Perbandingan kinerja model prediksi cuaca: Random Forest, Support Vector Regression, dan XGBoost. Edumatic: Jurnal Pendidikan Informatika, 8(2), 526-534. <https://doi.org/10.29408/edumatic.v8i2.27640>
- Tantyoko, H., Sari, D. K., & Wijaya, A. R. (2023). Prediksi potensial gempa bumi Indonesia menggunakan metode Random Forest dan feature selection, 6, 83-89.
- Urrochman, M. Y., & Hizham, F. A. (2025). Performance comparison of Random Forest Regression and SVR, 21(1), 16-23. <https://doi.org/10.33480/pilar.v21i1.6072>
- Wijaya, S. (2023). Analysis of the comparison between Linear Regression, Random Forest, and Logistic Regression methods in predicting crude palm oil (CPO) price, 3(2), 243-250.