

## OPTIMALISASI MODEL PERAMALAN PENJUALAN DENGAN PENDEKATAN ALGORITMA *LIGHT GRADIENT BOOSTING MACHINE* (LIGHTGBM)

Daffa Raihan<sup>1</sup>, Imran Lubis<sup>\*2</sup>

<sup>1,2</sup>Universitas Harapan Medan, Fakultas Teknik dan Komputer, Teknik Informatika  
Email: <sup>1</sup>[daffa.raihan@gmail.com](mailto:daffa.raihan@gmail.com), <sup>2</sup>[imran.loebis.medan@gmail.com](mailto:imran.loebis.medan@gmail.com)

### SEJARAH ARTIKEL

Diterima: 22.12.2025

Direvisi: 30.12.2025

Publish: 31.12.2025



Hak Cipta © 2025  
Penulis: Ini adalah  
artikel akses terbuka  
yang didistribusikan  
berdasarkan ketentuan  
Creative Commons  
Attribution 4.0  
International License.

### ABSTRAK

PT Kalbe Farma Tbk menghadapi kendala karena proses peramalan masih dilakukan secara manual, sehingga hasilnya rentan bias, tidak konsisten, dan sulit dievaluasi. Hal ini melatarbelakangi penelitian dengan rumusan masalah: bagaimana membangun alur data yang rapi untuk mendukung evaluasi model, sejauh mana algoritma LightGBM dapat meningkatkan akurasi prediksi dibandingkan pendekatan sederhana, serta bagaimana hasil peramalan dapat diintegrasikan ke dalam perencanaan operasional perusahaan. Tujuan penelitian ini adalah merancang dan mengimplementasikan sistem peramalan berbasis LightGBM dengan pipeline data terstruktur, melakukan evaluasi kinerja model, serta menyajikan hasil prediksi dalam bentuk antarmuka aplikasi web. Hasil implementasi menunjukkan bahwa sistem berhasil dibangun dengan fungsi utama meliputi pengelolaan data obat, pemanggilan algoritma LightGBM, dan penyajian hasil evaluasi dalam bentuk tabel maupun grafik. Model LightGBM mampu memanfaatkan fitur lag dan rata-rata bergerak untuk menangkap pola historis, namun hasil evaluasi masih menunjukkan error yang cukup tinggi dengan nilai MSE, RMSE, dan MAE yang besar serta  $R^2$  negatif. Temuan ini mengindikasikan bahwa model dasar belum optimal, tetapi sistem telah memberikan landasan penting bagi pengembangan lebih lanjut. Kesimpulannya, sistem ini dapat menjadi prototipe awal untuk mendukung proses perencanaan berbasis data di PT Kalbe Farma Tbk, dengan potensi peningkatan melalui optimasi parameter, perluasan dataset, dan integrasi variabel eksternal.

**Kata kunci:** peramalan, lightgbm, penjualan farmasi

### ABSTRACT

PT Kalbe Farma Tbk faces obstacles because the forecasting process is still done manually, so the results are prone to bias, inconsistent, and difficult to evaluate. This is the background for this study with the following research questions: how to build a neat data flow to support model evaluation, to what extent the LightGBM algorithm can improve prediction accuracy compared to simple approaches, and how forecasting results can be integrated into the company's operational planning. The objectives of this study are to design and implement a LightGBM-based forecasting system with a structured data pipeline, evaluate model performance, and present prediction results in the form of a web application interface. The implementation results show that the system was successfully built with main functions including drug data management, LightGBM algorithm invocation, and presentation of evaluation results in the form of tables and graphs. The LightGBM model is capable of utilizing lag and moving average features to capture historical patterns, but the evaluation results still show a fairly high error with large MSE, RMSE, and MAE values and a negative  $R^2$ . These findings indicate that the basic model is not yet optimal, but the system has provided an important foundation for further development. In conclusion, this system can be an initial prototype to support data-based planning processes at PT Kalbe Farma Tbk, with potential for improvement through parameter optimization, dataset expansion, and integration of external variables.

**Keywords:** forecasting, lightgbm, pharmaceutical sales

## 1. PENDAHULUAN

Peramalan adalah proses estimasi nilai masa depan berdasarkan pola pada data historis dan variabel penjelas yang relevan. Dalam konteks operasi bisnis, ketepatan peramalan menentukan kualitas perencanaan kapasitas, pengadaan, serta kebijakan persediaan. Tantangan utama terletak pada kemampuan model untuk menangkap tren, musiman, dan perubahan perilaku pasar secara nonlinier tanpa mengorbankan generalisasi. Dengan landasan tersebut, peramalan yang andal menjadi kunci untuk menekan ketidakpastian dan mendukung pengambilan keputusan yang konsisten [1].

Pada industri farmasi, kebutuhan peramalan semakin krusial karena penjualan produk dipengaruhi oleh dinamika terapi, kebijakan harga, promosi, dan perilaku kanal distribusi. Bagi PT Kalbe Farma Tbk, akurasi peramalan pada tingkat nama obat berdampak langsung pada ketersediaan produk dan efisiensi modal kerja. Data yang tersedia berupa nama obat sebagai identitas SKU, tahun sebagai penanda waktu, dan total penjualan sebagai target memungkinkan penyusunan model panel per obat lintas tahun. Dengan pendekatan ini, perusahaan dapat mengarahkan keputusan pengadaan dan alokasi persediaan berdasarkan informasi yang kuantitatif dan terukur pada setiap SKU [2].

Di lingkungan operasional perusahaan saat ini belum tersedia sistem peramalan yang terotomasi dan terstandar lintas unit sehingga estimasi permintaan cenderung disusun secara manual. Ketergantungan pada rekap historis sederhana dan penilaian subjektif membuat hasil prediksi rentan bias, tidak konsisten antarproduk dan wilayah, sulit direplikasi, serta memakan waktu. Keterbatasan alur data yang terstruktur untuk kolom nama obat, tahun, dan total penjualan juga menyulitkan proses uji balik dan pengukuran kinerja model secara berkala. Kondisi ini meningkatkan risiko kekurangan persediaan maupun kelebihan stok serta membatasi kemampuan menjalankan perencanaan penjualan dan operasi yang berbasis data.

Menjawab kondisi tersebut, penelitian ini mengembangkan sistem peramalan berbasis *Light Gradient Boosting Machine* yang bekerja langsung pada panel data nama obat per tahun dengan target total penjualan. Rekayasa fitur mencakup lag per obat, rata rata berjalan, pertumbuhan tahunan, indikator perubahan komposisi portofolio, serta pengendalian nilai hilang dan pencilaan. Proses pelatihan menerapkan validasi bergulir per obat untuk mencegah kebocoran informasi dan memastikan daya umum model. Kinerja dievaluasi menggunakan MAPE dan RMSE yang disejajarkan dengan biaya bisnis, disertai analisis kontribusi fitur agar keputusan mudah diaudit. Arsitektur ini dirancang modular sehingga ketika data diperluas hingga tingkat bulanan, skema fitur dan validasi dapat diterapkan ulang tanpa mengganggu konsistensi, menghasilkan rekomendasi peramalan yang lebih presisi bagi perencanaan pengadaan dan alokasi persediaan [3].

Penelitian dilakukan oleh [4] permasalahan yang diangkat adalah kebutuhan prediksi diabetes yang andal pada data klinis Pima Indians yang heterogen dan mengandung nilai hilang, sementara model tunggal sering gagal menangkap pola nonlinier secara efektif. Solusi yang diuji menggabungkan KNN dan LightGBM dengan exploratory data analysis, imputasi, normalisasi, validasi K-Fold, serta optimasi hiperparameter menggunakan pencarian acak dan pencarian grid. Dievaluasi dengan F1, ROC, precision recall, dan akurasi, pendekatan ini mencapai akurasi tertinggi 90,6 persen, menunjukkan peningkatan kinerja yang konsisten dibandingkan metode tunggal.

## 2. METODE PENELITIAN

### 2.1. Peramalan

Peramalan adalah proses memperkirakan nilai di masa depan dengan memanfaatkan informasi dari masa lalu dan pemahaman tentang mekanisme yang membentuk data. Tujuannya bukan meramal secara serampangan, melainkan menyusun estimasi yang dapat diuji, direplikasi, dan dibandingkan kinerjanya. Di sini, peramalan dibedakan dari penetapan target; target bersifat normatif, sedangkan ramalan bersifat deskriptif tentang apa yang kemungkinan terjadi jika tidak ada intervensi tambahan. Definisi ini mencakup peramalan deret waktu, peramalan berbasis regresi dengan variabel penjelas, hingga pendekatan panel yang menggabungkan banyak entitas sepanjang waktu. Agar bermakna, peramalan harus menjelaskan apa yang diramalkan, untuk horizon berapa lama, dan pada tingkat agregasi apa. Besaran yang diprediksi bisa berupa volume penjualan, permintaan, atau variabel finansial lain, sementara horizon dapat berskala harian, bulanan, atau tahunan. Struktur data umumnya memuat komponen tren, musiman, siklus, dan komponen acak yang tidak dijelaskan. Selain itu, banyak konteks dipengaruhi pemicu eksternal seperti harga, promosi, kalender libur, atau peristiwa khusus yang perlu dipertimbangkan agar ramalan tidak terputus dari realitas operasional. Setiap model peramalan membawa asumsi tentang cara data dihasilkan. Sebagian metode menghendaki kestasioneran, sebagian lain dapat menoleransi perubahan rezim, dan sebagian besar hanya mendekati mekanisme sebenarnya. Karena itu, peramalan yang bertanggung jawab selalu mengakui bahwa model adalah penyederhanaan, bukan cermin sempurna dari dunia. Konsekuensinya, pengetahuan domain diperlukan untuk memeriksa kewajaran hasil, mendeteksi pergeseran struktur, serta menghindari kesimpulan yang tidak sah [2].

## 2.2. Machine Learning

*Machine Learning* atau pembelajaran mesin adalah cabang dari kecerdasan buatan (Artificial Intelligence) yang berfokus pada pengembangan algoritma dan model yang mampu belajar dari data. Berbeda dengan pemrograman tradisional yang mengandalkan aturan eksplisit, *Machine Learning* memungkinkan sistem untuk menemukan pola dan membuat keputusan berdasarkan pengalaman yang diperoleh dari data historis. Konsep utama dalam *Machine Learning* adalah kemampuan sistem untuk meningkatkan kinerjanya secara bertahap seiring bertambahnya data yang diproses. Artinya, semakin banyak data yang digunakan, semakin baik model dalam mengenali pola dan melakukan prediksi [5]–[8]. Pendekatan ini banyak digunakan pada berbagai bidang, mulai dari pengenalan wajah, deteksi penipuan, peramalan penjualan, hingga rekomendasi produk. *Machine Learning* dapat diklasifikasikan ke dalam beberapa kategori utama. Pertama, supervised learning, di mana model belajar dari data yang sudah diberi label untuk memprediksi output pada data baru. Kedua, unsupervised learning, di mana model mencari pola tersembunyi atau struktur dalam data tanpa label. Ketiga, reinforcement learning, yang menekankan proses belajar melalui interaksi dengan lingkungan untuk memaksimalkan reward [9].

## 2.3. Light Gradient Boosting Machine (LightGBM)

*Light Gradient Boosting Machine* (LightGBM) adalah algoritma pembelajaran mesin berbasis *gradient boosting decision tree* (GBDT). Algoritma ini menggunakan pendekatan *boosting*, yaitu membangun model secara bertahap dengan cara menambahkan pohon keputusan baru yang berfokus pada memperbaiki kesalahan dari pohon sebelumnya. Dibandingkan metode boosting tradisional, LightGBM lebih efisien karena menggunakan *histogram-based algorithm* dan strategi pertumbuhan pohon *leaf-wise* sehingga mampu menangani data berskala besar dengan cepat tanpa kehilangan akurasi. Dalam boosting, model akhir dibentuk dari kombinasi sejumlah pohon keputusan sederhana (*weak learners*) [10]. Setiap iterasi mencoba meminimalkan fungsi kerugian (loss function) dengan memanfaatkan gradien dari kesalahan model sebelumnya. Secara umum, model boosting dituliskan sebagai:

$$F_m(x) = F_{m-1}(x) + \eta \cdot h_m(x) \quad (1)$$

dengan keterangan:

$F_m(x)$  : model pada iterasi ke-m  
 $F_{m-1}(x)$  : model pada iterasi sebelumnya  
 $h_m(x)$  : pohon keputusan baru (weak learner) yang dilatih berdasarkan gradien  
 $\eta$  : *learning rate* yang mengatur kontribusi setiap pohon

Pada setiap iterasi, LightGBM membangun pohon baru dengan meminimalkan fungsi kerugian  $L(y, F(x))$ , di mana:

$$g_i = \frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \quad h_i = \frac{\partial^2 L(y_i, F(x_i))}{\partial F(x_i)^2} \quad (2)$$

dengan keterangan:

$g_i$  : gradien (turunan pertama dari loss function)  
 $h_i$  : hessian (turunan kedua dari loss function)  
 $y_i$  : nilai aktual  
 $F(x_i)$  : prediksi model saat ini

LightGBM memperbarui model dengan menambahkan nilai prediksi di tiap daun pohon. Nilai optimal untuk sebuah daun dihitung dengan formula:

$$w_j = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (3)$$

dengan keterangan:

$w_j$  : nilai prediksi pada daun j  
 $I_j$  : indeks sampel yang masuk ke daun j  
 $g_i$  : gradien untuk data i  
 $h_i$  : hessian untuk data i  
 $\lambda$  : parameter regularisasi untuk mencegah overfitting

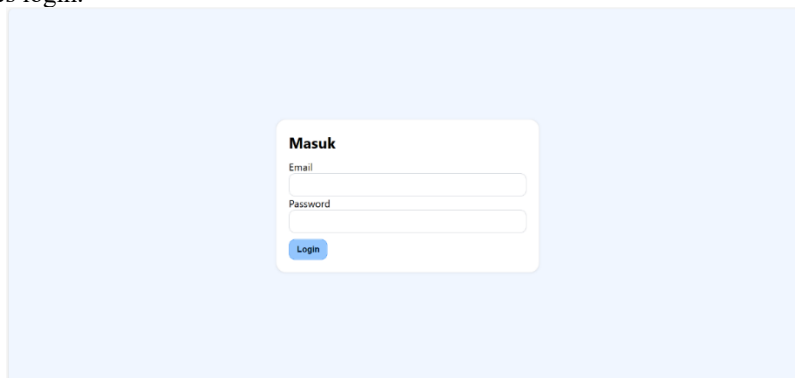
## 3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan bagaimana rancangan sistem diimplementasikan ke dalam aplikasi yang berjalan serta kinerja yang dihasilkannya. Implementasi meliputi penyusunan basis data, layanan inti, dan antarmuka pengguna, diikuti pengujian fungsi dan beban terbatas.

### 1. Halaman Login

Halaman login berfungsi sebagai pintu masuk sistem untuk memverifikasi identitas pengguna. Pada tahap ini, pengguna diminta memasukkan email dan password yang terdaftar dalam basis data. Data yang diinput kemudian diproses untuk dicocokkan dengan kredensial yang valid. Jika sesuai, pengguna diberi akses ke

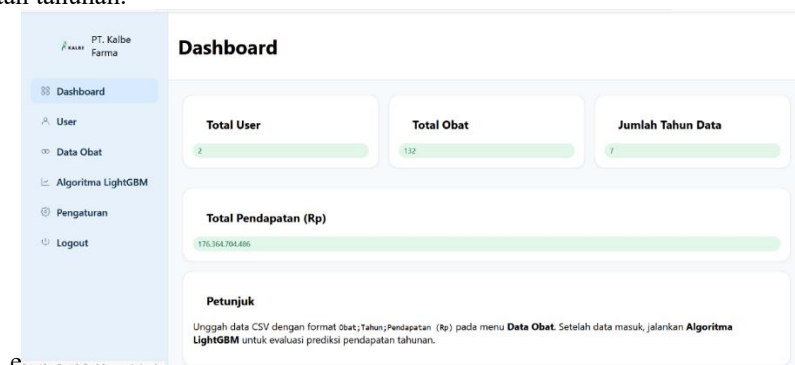
dashboard dan fitur utama sistem; sebaliknya, jika tidak valid, sistem akan menolak dan meminta pengguna mengulangi proses login.



Gambar 1. Halaman Login

## 2. Halaman Dashboard

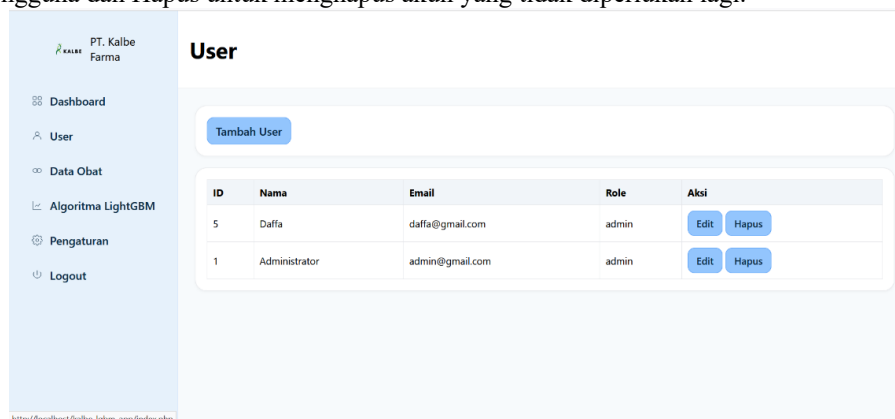
Dashboard pada sistem ini berfungsi menampilkan ringkasan informasi penting secara cepat dan ringkas. Melalui halaman ini, pengguna dapat melihat jumlah total pengguna, total data obat yang tercatat, rentang tahun data yang tersedia, serta akumulasi total pendapatan dalam satuan rupiah. Informasi ini diperoleh dari data yang sudah diunggah ke dalam sistem dan divisualisasikan dalam bentuk kartu indikator agar mudah dipantau. Selain itu, dashboard juga menyediakan petunjuk singkat mengenai alur penggunaan sistem, khususnya cara mengunggah data obat dalam format CSV serta menjalankan algoritma LightGBM untuk melakukan evaluasi prediksi pendapatan tahunan.



Gambar 1 Halaman Dashboard

## 3. Halaman User

Halaman User pada sistem ini digunakan untuk mengelola data pengguna yang memiliki akses ke aplikasi. Dari tampilan terlihat bahwa sistem menampilkan daftar pengguna dalam bentuk tabel yang berisi informasi seperti ID, nama, email, serta role masing-masing pengguna. Selain itu, tersedia pula tombol Tambah User untuk menambahkan pengguna baru ke dalam sistem. Pada setiap baris data, disediakan fitur Edit untuk memperbarui informasi pengguna dan Hapus untuk menghapus akun yang tidak diperlukan lagi.



Gambar 3. Halaman User

## 4. Halaman Data Obat

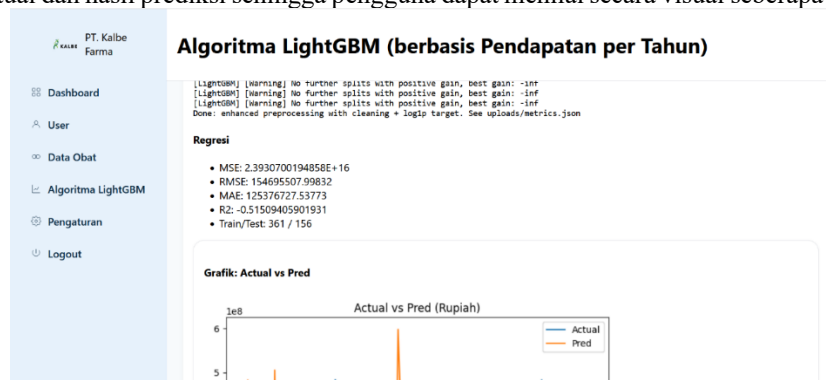
Halaman Data Obat berfungsi sebagai pusat pengelolaan informasi obat beserta data pendapatan tahunan yang terkait. Melalui menu ini, pengguna dapat menambahkan data obat secara manual dengan tombol Tambah Obat atau mengunggah file dalam format CSV yang berisi kolom Obat;Tahun;Pendapatan (Rp). Data yang sudah masuk akan ditampilkan dalam bentuk tabel, lengkap dengan informasi nama obat, tahun, serta pendapatan yang tercatat. Untuk setiap baris data, tersedia tombol Edit untuk memperbarui informasi dan Hapus untuk menghilangkan data yang tidak diperlukan.



Gambar 4. Halaman Data Obat

#### 5. Halaman Algoritma LightGBM

Halaman Algoritma LightGBM menampilkan hasil implementasi model pembelajaran mesin yang digunakan untuk memprediksi pendapatan tahunan berdasarkan data obat. Proses ini menghasilkan beberapa indikator evaluasi, seperti nilai kesalahan kuadrat rata-rata (MSE), kesalahan kuadrat rata-rata akar (RMSE), kesalahan absolut rata-rata (MAE), serta nilai koefisien determinasi ( $R^2$ ) yang mencerminkan kemampuan model dalam menjelaskan variasi data. Selain menampilkan metrik numerik, sistem juga menyajikan grafik perbandingan antara data aktual dan hasil prediksi sehingga pengguna dapat menilai secara visual seberapa baik model bekerja.



Gambar 5. Halaman Algoritma

Hasil evaluasi regresi dari algoritma LightGBM dibawah ini menunjukkan bahwa performa model masih jauh dari optimal. Nilai MSE yang sangat besar dan RMSE mencapai lebih dari 154 juta rupiah memperlihatkan bahwa tingkat kesalahan prediksi rata-rata cukup tinggi. Demikian pula, MAE yang berada pada kisaran 125 juta rupiah menunjukkan adanya deviasi signifikan antara nilai aktual dengan hasil prediksi. Sementara itu, nilai  $R^2$  yang negatif menandakan bahwa model bahkan tidak mampu menjelaskan variasi data dengan baik, sehingga kinerjanya lebih buruk daripada sekadar menggunakan nilai rata-rata sebagai prediksi. Data yang digunakan dalam pelatihan dan pengujian terdiri dari 361 sampel untuk training serta 156 sampel untuk testing.


#### Regresi

- MSE: 2.3930700194858E+16
- RMSE: 154695507.99832
- MAE: 125376727.53773
- R2: -0.51509405901931
- Train/Test: 361 / 156

Gambar 6. Halaman Regresi

Grafik Actual vs Pred dibawah ini menggambarkan perbandingan antara nilai pendapatan aktual dengan hasil prediksi yang dihasilkan oleh model LightGBM. Garis biru mewakili data aktual, sedangkan garis oranye menunjukkan nilai prediksi. Dari grafik terlihat bahwa meskipun pola fluktuasi data prediksi sesekali mengikuti tren aktual, terdapat banyak titik di mana prediksi menyimpang cukup jauh dari nilai sebenarnya. Perbedaan ini menunjukkan bahwa akurasi model masih rendah, selaras dengan hasil metrik evaluasi yang sebelumnya ditampilkan, seperti nilai error yang tinggi dan  $R^2$  negatif

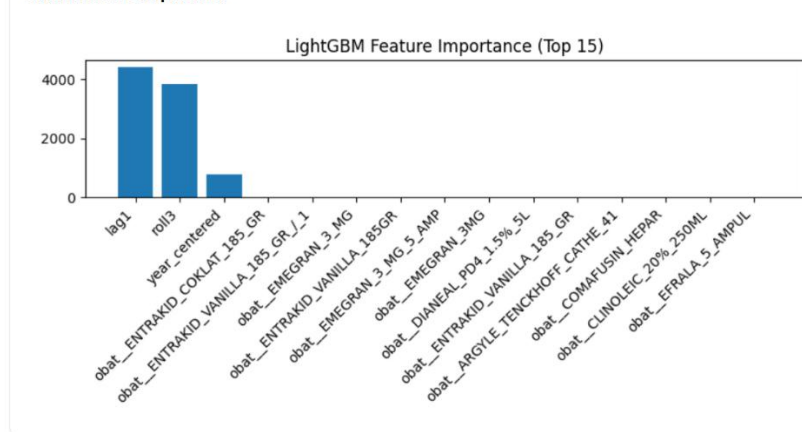
Grafik: Actual vs Pred



Gambar 7. Grafik Actual dan Prediksi

Grafik *Feature Importance* dibawah ini memperlihatkan variabel-variabel yang paling berpengaruh dalam model LightGBM terhadap prediksi pendapatan per tahun. Dari hasil terlihat bahwa fitur lag1 dan roll3 memiliki bobot paling tinggi dibandingkan fitur lainnya, yang berarti variabel-variabel berbasis riwayat data (seperti nilai sebelumnya atau rata-rata bergulir) sangat dominan dalam memengaruhi hasil prediksi. Sementara itu, fitur lain seperti year\_centered dan beberapa nama obat tertentu hanya memberikan kontribusi yang relatif kecil terhadap performa model. Kondisi ini menunjukkan bahwa pola historis pendapatan lebih menentukan hasil prediksi dibandingkan dengan identitas obat secara individual. Dengan demikian, meskipun model menggunakan banyak variabel, kekuatan prediksi LightGBM pada data ini terutama ditopang oleh fitur berbasis waktu, sehingga peningkatan kualitas data historis kemungkinan besar akan lebih signifikan dalam memperbaiki akurasi model.

Grafik: Feature Importance



Gambar 8. Grafik *Feature Importance*

#### 4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa sistem peramalan penjualan berbasis algoritma LightGBM di PT Kalbe Farma Tbk berhasil dirancang dan diimplementasikan dengan baik. Sistem ini mampu mengelola data penjualan obat secara terstruktur dan digunakan sebagai input dalam proses peramalan serta evaluasi model. Hasil pengujian menunjukkan bahwa algoritma LightGBM dapat menangkap pola historis penjualan melalui pemanfaatan fitur lag dan rolling average, namun tingkat akurasi yang dihasilkan masih belum optimal, ditunjukkan oleh nilai error yang relatif tinggi dan nilai  $R^2$  yang negatif. Meskipun demikian, sistem telah terintegrasi dalam aplikasi berbasis web sehingga memudahkan pengguna dalam mengelola data dan melihat hasil prediksi. Secara keseluruhan, sistem ini dapat dijadikan sebagai prototipe awal peramalan penjualan berbasis

data, yang masih memiliki peluang untuk dikembangkan lebih lanjut guna meningkatkan akurasi dan mendukung pengambilan keputusan bisnis secara lebih andal.

#### DAFTAR PUSTAKA

- [1] I. Winarto, R. H. A. Shiddieqy, and S. T. Rivai Wardhani, *Manajemen Operasi, Perencanaan Produksi, dan Pengendalian Persediaan*. Penerbit Andi, 2025.
- [2] M. Irsyad, “Visualisasi tableau perkiraan volume penjualan dan perhitungan reorder point produk farmasi menggunakan metode Autoregressive Integrated Moving Average (ARIMA)(studi kasus: PT Kimia Farma Tbk).” Fakultas Sains Teknologi UIN Syarif Hidayatullah Jakarta, 2024.
- [3] M. T. Rahffi, “Implementasi Machine Learning dalam memprediksi Jumlah Pendonor Darah dengan menggunakan Model Autoregressive Integrated Moving Average (ARIMA) dan Exponential Moving Average (EMA)(Studi Kasus: PMI Kabupaten Sleman).” Universitas Islam Indonesia, 2024.
- [4] A. Pramudyantoro, E. Utami, and D. Ariatmanto, “PENGGABUNGAN K-NEAREST NEIGHBORS DAN LIGHTGBM UNTUK PREDIKSI DIABETES PADA DATASET PIMA INDIANS: MENGGUNAKAN PENDEKATAN EXPLORATORY DATA ANALYSIS,” vol. 9, no. 3, pp. 1133–1144, 2024.
- [5] I. P. Putri, “Analisis Performa Metode K- Nearest Neighbor (KNN) dan Crossvalidation pada Data Penyakit Cardiovascular,” *Indones. J. Data Sci.*, vol. 2, no. 1, pp. 21–28, 2021, doi: 10.33096/ijodas.v2i1.25.
- [6] E. Wahyudi, B. Imran, S. Erniwati, M. N. Karim, I. Pemerintahan, and D. Negeri, “FINE-TUNING RESNET50V2 WITH ADAMW AND ADAPTIVE TRANSFER LEARNING FOR SONGKET CLASSIFICATION IN LOMBOK,” *Pilar Nusa Mandiri*, vol. 21, no. 1, pp. 82–91, 2025, doi: 10.33480/pilar.v21i1.6485.
- [7] B. Imran, Zaeniah, Sriasih, S. Erniwati, and Salman, “Data Mining Using a Support Vector Machine , Decision Tree , Logistic Regression and Random Forest for,” *J. Infokum*, vol. 10, no. 2, pp. 792–802, 2022.
- [8] D. Hananta Firdaus, B. Imran, L. Darmawan Bakti, and E. Suryadi, “Klasifikasi Penyakit Katarak Pada Mata Menggunakan Metode Convolutional Neural Network (Cnn) Berbasis Web,” *J. Kecerdasan Buatan dan Teknol. Inf.*, vol. 1, no. 3, pp. 18–26, 2022.
- [9] A. A. Nampira *et al.*, *Artificial Intelligence: A Guide for Thinking Humans*. PT. Green Pustaka Indonesia, 2025.
- [10] W. Wardalisah, “Peramalan Harga Saham menggunakan Metode Light Gradient Boosting Machine dengan Optuna Hyperparameter Optimization (Studi Kasus: Saham PT. Vale Indonesia Tbk.)= Stock Price Forecasting using Light Gradient Boosting Machine Method with Optuna Hyperparamete.” Universitas Hasanuddin, 2024.