

Analisis Perbandingan XGBoost dan LightGBM dalam Prediksi Penjualan Ritel Walmart Store Sales

I Gusti Ayu Riyani Astarani^{a1}, I Gede Surya Rahayuda^{a2}

Program Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Udayana
Jalan Raya Kampus Udayana, Bukit Jimbaran, Kuta Selatan, Badung, Bali, Indonesia
¹astarani.2308561033@student.unud.ac.id
²igedesuryarahayuda@unud.ac.id

Abstract

Sales prediction is a crucial aspect in the retail industry for optimizing business strategies and inventory management. As a global retail company with a large-scale operation, Walmart faces significant challenges in efficiently managing its supply chain and inventory. This study conducts a comparative analysis between the Extreme Gradient Boosting (XGBoost) and Light Gradient Boosting Machine (LightGBM) algorithms in the context of retail sales prediction using the Walmart Store Sales dataset. The dataset consists of 6,436 records with 8 attributes. The research methodology implements a comprehensive machine learning approach, including data preprocessing, feature selection, dataset splitting (80:20), model training, and evaluation using standard metrics. The analysis results show that LightGBM provides superior prediction performance, with an MSE of 0.0341, MAE of 0.1120, RMSE of 0.1847, and R^2 of 0.9663. In comparison, XGBoost yields an MSE of 0.0408, MAE of 0.1194, RMSE of 0.2021, and R^2 of 0.9596. The consistent superiority of LightGBM across all evaluation metrics indicates that this algorithm is more optimal for the Walmart sales prediction case. Additionally, feature analysis shows that the variable Store contributes the most to the predictive model, while Fuel Price has a relatively minor impact. This study emphasizes that selecting the appropriate machine learning algorithm significantly affects optimal prediction outcomes, particularly in a complex, data-driven retail industry.

Keywords: Sales Prediction, XGBoost, LightGBM, Machine Learning, Walmart Store Sales

1. Pendahuluan

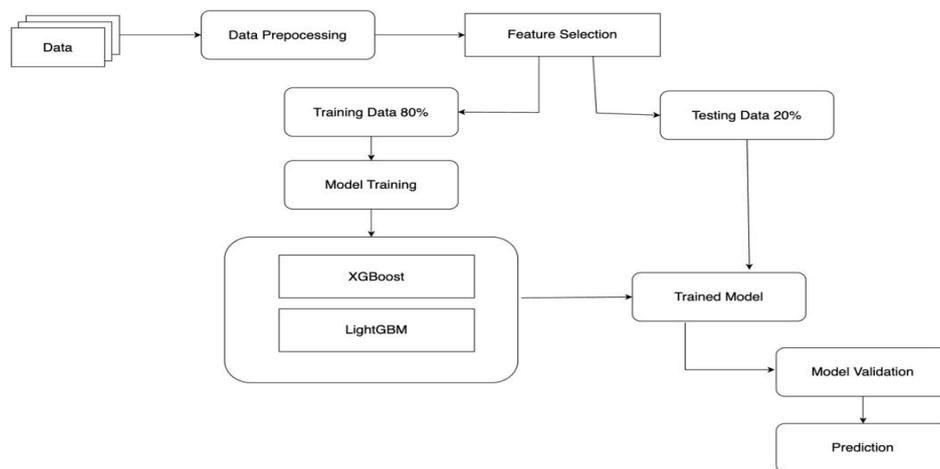
Dalam dunia bisnis modern, kemampuan untuk meramalkan permintaan secara akurat menjadi salah satu aspek krusial dalam pengambilan keputusan strategis. Ketepatan prediksi penjualan tidak hanya berperan dalam memastikan ketersediaan produk bagi konsumen, tetapi juga berdampak langsung pada efisiensi logistik, pengelolaan persediaan, dan pengendalian biaya operasional. Di sektor ritel yang sangat dinamis, berbagai faktor eksternal seperti perubahan musim, promosi, tren konsumen, dan fluktuasi harga dapat mempengaruhi volume penjualan secara signifikan, sehingga menjadikan proses peramalan sebagai tantangan yang kompleks salah satunya dihadapi oleh perusahaan ritel besar seperti Walmart. Walmart adalah salah satu perusahaan ritel terbesar di dunia yang beroperasi di berbagai negara dengan ribuan toko. Dengan skala operasional yang luas, Walmart menghadapi tantangan besar dalam mengelola persediaan dan memenuhi permintaan pelanggan secara efisien. Prediksi penjualan yang akurat menjadi faktor kunci dalam optimalisasi rantai pasokan, pengurangan biaya penyimpanan, serta peningkatan kepuasan pelanggan. Namun, dinamika pasar yang cepat, faktor eksternal seperti perubahan musim, tren konsumen, dan kebijakan harga menjadikan peramalan penjualan sebagai tantangan yang kompleks. Dalam beberapa tahun terakhir, *Machine Learning* (ML) telah menjadi pendekatan utama dalam prediksi penjualan karena kemampuannya dalam menangkap pola non-linear dari data historis. Seiring meningkatnya kebutuhan akan data yang lebih besar dan akurat, khususnya di perusahaan berskala besar seperti Walmart, konsep Big Data menjadi semakin relevan dalam konteks prediksi penjualan ritel. Big Data memiliki lima karakteristik utama yang dikenal dengan istilah 5V. Pertama, Volume, yaitu jumlah data yang sangat besar, seperti

jutaan transaksi harian yang terjadi di berbagai cabang toko. Kedua, Velocity, menggambarkan kecepatan tinggi dalam menghasilkan dan memproses data secara real-time. Ketiga, Variety, yang menunjukkan keragaman bentuk dan sumber data, misalnya dari penjualan, stok barang, cuaca, hingga media sosial. Keempat, Veracity, yaitu tingkat keakuratan dan keandalan data yang harus dijaga agar hasil analisis tetap valid. Terakhir, Value, yang merujuk pada nilai atau manfaat bisnis yang diperoleh dari pengolahan data tersebut. Kelima aspek ini saling berkaitan dan menjadi fondasi penting dalam pengelolaan data skala besar untuk meningkatkan akurasi prediksi penjualan di sektor ritel. Berbagai algoritma telah diterapkan dalam studi sebelumnya untuk meningkatkan akurasi prediksi penjualan ritel. Salah satu pendekatan yang digunakan adalah algoritma *decision tree* seperti C4.5. Penelitian tersebut dilakukan oleh [1] menggunakan algoritma C4.5 untuk memprediksi penjualan Walmart berdasarkan data historis, dengan hasil akurasi mencapai 94%, precision 43%, dan recall 75%. Namun, metode ini memiliki keterbatasan dalam menangani dataset besar dan kompleks dengan banyak variabel. Selain itu, model berbasis *deep learning* juga banyak digunakan. Penelitian yang dilakukan oleh [2] menerapkan model *Long Short-Term Memory* (LSTM) untuk menganalisis data transaksi dari tahun 2014 hingga 2016 di sebuah supermarket di Taiwan. LSTM terbukti mampu menangkap pola musiman dan tren penjualan dengan akurasi yang lebih tinggi dibandingkan metode statistik tradisional, sehingga menjadikannya pilihan yang efektif untuk prediksi jangka panjang. Namun, terdapat kekurangan yakni model ini memerlukan waktu pelatihan yang lebih lama dan sumber daya komputasi yang besar. Pendekatan lain yang populer dalam prediksi penjualan adalah *ensemble learning*, seperti algoritma *Extreme Gradient Boosting* (XGBoost). Penelitian ini dilakukan oleh [3] dimana peneliti menerapkan XGBoost dalam kerangka kerja CRISP-DM untuk peramalan penjualan produk di UB Mart, hasilnya menunjukkan bahwa model ini mampu mengoptimalkan manajemen persediaan dan meningkatkan efisiensi operasional. Meskipun XGBoost unggul dalam menangani data dengan fitur yang kompleks, model ini rentan terhadap pemilihan parameter yang tidak optimal, yang dapat menyebabkan overfitting atau performa suboptimal. Selain XGBoost, *Light Gradient Boosting Machine* (LightGBM) telah menjadi alternatif yang lebih efisien dalam peramalan berbasis *gradient boosting*. Penelitian ini dilakukan oleh [4] yang menunjukkan bahwa kombinasi LSTM dan LightGBM dapat meningkatkan akurasi prediksi dibandingkan model regresi linear atau *Support Vector Machine* (SVM). Keunggulan LightGBM terletak pada kecepatan pemrosesan dan kemampuannya dalam menangani data skala besar tanpa mengorbankan akurasi. Meskipun berbagai metode telah diterapkan, tantangan masih ada dalam meningkatkan akurasi dan efisiensi peramalan penjualan di sektor ritel. Dengan mempertimbangkan berbagai keterbatasan yang ditemukan pada studi terdahulu, penelitian ini berkontribusi dengan secara khusus membandingkan kinerja dua algoritma *gradient boosting* terkemuka, yaitu XGBoost dan LightGBM, dalam memprediksi penjualan ritel pada skala besar menggunakan data Walmart. Berbeda dengan penelitian sebelumnya yang umumnya hanya menguji salah satu algoritma atau menggabungkannya dengan model lain, studi ini menempatkan kedua model pada dataset yang sama dan mengevaluasinya secara komprehensif menggunakan berbagai metrik, termasuk RMSE, MAE, MSE, dan R^2 , sehingga menghasilkan analisis yang lebih objektif terhadap kelebihan dan kelemahan masing-masing model. Penelitian ini diharapkan dapat memberikan rekomendasi mengenai model yang paling sesuai untuk diterapkan dalam konteks ritel.

2. Metode Penelitian

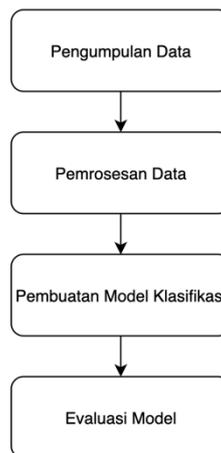
Metode penelitian merupakan serangkaian langkah yang dilakukan untuk menyelesaikan permasalahan dalam penelitian dengan mengikuti aturan yang telah ditetapkan agar penelitian dapat mencapai hasil yang optimal sesuai dengan tujuan yang diharapkan. Salah satu permasalahan terpenting dalam pemodelan prediktif adalah pemilihan dan pelatihan model *machine learning* yang tepat agar dapat melakukan generalisasi dengan baik pada data yang belum pernah dilihat sebelumnya. Metode klasik biasanya mengalami satu atau lebih dari permasalahan berikut, yang menyebabkan modelnya tidak memberikan prediksi yang akurat. Untuk mengatasi tantangan ini, diterapkan sebuah pipeline *machine learning* end-to-end yang sistematis, seperti yang digambarkan pada diagram alir **Gambar 1**. Proses dimulai dengan *Data Preprocessing*, di mana data mentah dikumpulkan, dibersihkan dari nilai yang hilang, serta dinormalisasi agar sesuai dengan kebutuhan model. Setelah itu, dilakukan *Feature Selection*, yaitu pemilihan fitur yang paling relevan guna meningkatkan akurasi model serta mengurangi

kompleksitas komputasi, sehingga model dapat bekerja lebih efisien dan menghindari risiko *overfitting*. Setelah fitur yang optimal dipilih, dataset dibagi menjadi dua subset yaitu 80% sebagai data latih dan 20% sebagai data uji. Data pelatihan kemudian digunakan dalam model training, di mana dua algoritma utama, yaitu *XGBoost* dan *LightGBM*, diterapkan untuk membangun model prediktif yang lebih akurat dan efisien. Setelah model selesai dilatih, hasilnya disimpan sebagai trained model, yang kemudian diuji menggunakan data pengujian yang telah disiapkan sebelumnya untuk mengevaluasi performanya terhadap data yang belum pernah dilihat sebelumnya. Tahap ini disebut Model Validation, yang bertujuan untuk mengukur performa model menggunakan matrik evaluasi seperti RMSE, MAE, MSE dan koefisien determinasi (R^2). Jika model telah mencapai kinerja yang optimal setelah validasi dan penyetelan, tahap akhir dilakukan, yaitu *prediction*. Berikut dijelaskan secara garis besar tahapan-tahapan dalam penelitian ini dapat dilihat pada **Gambar 1**.



Gambar 1. Pipeline Machine Learning

Secara sederhana inti dari penelitian ini dapat dilihat pada **Gambar 2**. Terdiri dari empat tahapan utama yaitu: Pengumpulan Data, Pemrosesan Data, Pembuatan Model Klasifikasi dan Evaluasi Model.



Gambar 2. Tahapan Penelitian

2.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah dataset penjualan Walmart, yang diperoleh dari Kaggle. Dataset ini mencakup informasi historis mengenai penjualan ritel di berbagai toko

Walmart. Data ini digunakan untuk menganalisis tren penjualan dan membangun model prediksi berdasarkan berbagai faktor yang mempengaruhi penjualan. Dataset Walmart yang digunakan bisa dilihat pada **Tabel 1** dimana terdiri dari jumlah data sebanyak 6.436 dengan 8 atribut, yang mencakup berbagai variabel yang dapat mempengaruhi penjualan di setiap toko. Informasi dalam dataset ini meliputi faktor ekonomi, tren musiman, serta variabel eksternal yang dapat mempengaruhi fluktuasi penjualan. Adapun variabel targetnya yakni atribut *Weekly_Sales* bisa dilihat pada **Tabel 2**.

Tabel 1. Deskripsi Atribut

Atribut	Deskripsi
Store	ID dari toko Walmart yang mencerminkan lokasi toko tersebut.
Date	Tanggal transaksi penjualan yang digunakan untuk analisis tren waktu.
Weekly_Sales	Jumlah total penjualan mingguan untuk setiap toko, yang menjadi target prediksi dalam penelitian ini.
Holiday_Flag	Indikator (0 atau 1) yang menunjukkan apakah minggu tersebut berisi hari libur nasional, yang dapat mempengaruhi volume penjualan.
Temperature	Suhu rata-rata dalam satuan Fahrenheit, yang dapat mempengaruhi perilaku belanja konsumen.
Fuel_Price	Harga bahan bakar di wilayah tempat toko beroperasi.
CPI (Consumer Price Index)	Indeks harga konsumen yang mencerminkan tingkat inflasi dan daya beli masyarakat.
Unemployment	Tingkat pengangguran di wilayah tempat toko berada.

Tabel 2. Variabel Target

Atribut	Deskripsi
Weekly_Sales	Jumlah total penjualan mingguan untuk setiap toko, yang menjadi target prediksi dalam penelitian ini.

2.2 Pemrosesan Data

Preprocessing data merupakan proses awal dalam *pipeline machine learning* yang bertujuan untuk menyiapkan data mentah agar layak dan optimal digunakan dalam proses pemodelan. Tujuan utama dari *preprocessing* ini adalah untuk membersihkan, mengubah, dan menstandarisasi data agar lebih optimal dan sesuai untuk digunakan dalam proses pemodelan. Tahapan *preprocessing* yang dilakukan dalam penelitian ini ditunjukkan pada **Gambar 3**.



Gambar 3. Tahap *Preprocessing* Data

a. Konversi Kolom Tanggal Menjadi Format Numerik

Tahapan awal dalam pemrosesan data dilakukan dengan mengonversi kolom tanggal ke dalam format numerik. Hal ini dilakukan karena data dalam format string tidak dapat digunakan secara langsung dalam analisis atau pelatihan model *machine learning*. Data tanggal yang semula berbentuk string dikonversi menjadi representasi numerik, seperti jumlah hari sejak tanggal tertentu atau dipisahkan menjadi tahun, bulan, dan hari. Transformasi ini penting untuk memastikan bahwa model dapat mengenali pola musiman

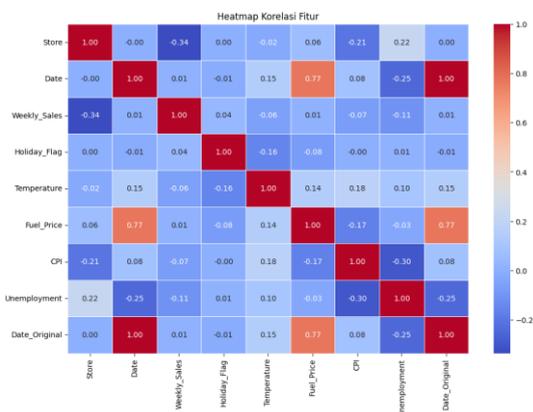
atau tren berdasarkan waktu dengan lebih baik.

b. Normalisasi Fitur Numerik

Setelah seluruh fitur waktu diubah ke bentuk numerik, proses dilanjutkan dengan normalisasi fitur numerik lainnya. Normalisasi dilakukan menggunakan metode *Standard Scaling* untuk menyetarakan skala semua fitur. Proses ini mengubah distribusi nilai fitur agar memiliki rata-rata nol dan standar deviasi satu. Tujuannya adalah agar model tidak bias terhadap fitur dengan skala lebih besar, serta membuat proses pelatihan model menjadi lebih stabil dan efisien.

c. Analisis Korelasi Fitur

Langkah berikutnya adalah analisis korelasi antar fitur, untuk melihat hubungan antara satu variabel dengan variabel lainnya serta mengidentifikasi fitur-fitur yang memiliki pengaruh signifikan terhadap target prediksi. Visualisasi dalam bentuk heatmap pada **Gambar 4**. menunjukkan tingkat korelasi antar seluruh fitur numerik dalam dataset Walmart. Analisis ini dilakukan menggunakan koefisien korelasi pearson, yang mengukur sejauh mana hubungan linear antara dua variabel.

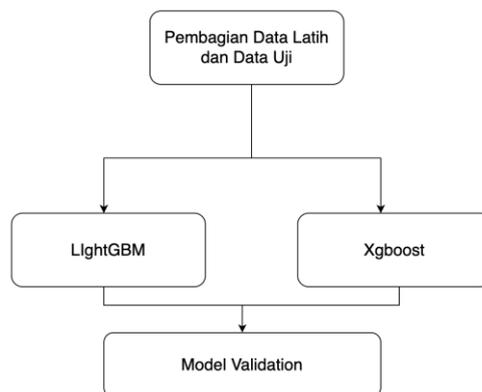


Gambar 4. Heatmap Korelasi Fitur

Seperti yang terlihat pada **Gambar 4** sebagian besar fitur dalam dataset memiliki korelasi yang lemah satu sama lain, yang mengindikasikan tidak adanya multikolinearitas tinggi yang dapat mengganggu proses pemodelan. Salah satu korelasi yang cukup menonjol terlihat antara fitur *Date* dan *Fuel_Price*, dengan nilai korelasi sebesar 0.77. Hal ini menunjukkan adanya tren musiman atau pengaruh waktu terhadap harga bahan bakar. Selain itu, fitur *Date_Original* juga menunjukkan korelasi yang sangat tinggi terhadap *Date*, yang wajar mengingat keduanya merupakan representasi berbeda dari informasi tanggal yang sama. Sementara itu, fitur target *Weekly_Sales* tidak menunjukkan korelasi yang kuat terhadap fitur lain secara langsung. Kondisi ini menegaskan perlunya penerapan model pembelajaran mesin untuk menangkap pola non-linear yang tidak terdeteksi melalui analisis korelasi sederhana. Dalam penelitian ini, seluruh fitur yang tersedia dalam dataset digunakan untuk memastikan tidak ada informasi yang terlewat dalam proses prediksi penjualan di Walmart. Dengan pendekatan ini, dataset tetap mempertahankan seluruh variabel yang berpotensi memberikan kontribusi terhadap kinerja model prediktif.

2.3 Pembuatan Model Klasifikasi

Tahapan pembuatan model dimulai dengan pembagian dataset menjadi 80% data latih dan 20% data uji untuk memastikan model dapat melakukan generalisasi dengan baik. Selanjutnya, model dilatih menggunakan *XGBoost* dan *LightGBM*. Model yang telah dilatih dievaluasi menggunakan RMSE, MAE, MSE dan koefisien determinasi (R^2) untuk mengukur akurasi prediksi. Tahapan pembuatan model yang dilakukan dalam penelitian ini ditunjukkan pada **Gambar 5**.



Gambar 5. Tahapan Pemodelan

Berikut penjelasan tahapan pembuatan model dari **Gambar 5**.

a. Pembagian Data latih dan Data uji

Sebelum model dilatih, dataset dibagi menjadi dua bagian utama, yaitu data training (*training set*) dan data testing (*testing set*). Proses ini dilakukan menggunakan fungsi *train_test_split* dari pustaka *sklearn.model_selection*. Pembagian data ini bertujuan memastikan bahwa model yang dibangun dapat mempelajari pola dalam data secara efektif dan diuji terhadap data yang belum pernah dilihat sebelumnya. Data training digunakan dalam proses pelatihan model, di mana model mempelajari hubungan antara fitur dan label yang tersedia. Sementara itu, data testing digunakan untuk mengevaluasi performa model terhadap data baru, sehingga dapat diketahui seberapa baik model mampu melakukan prediksi pada data yang tidak termasuk dalam proses pelatihan. Pembagian dilakukan dengan perbandingan 80% untuk data training dan 20% untuk data testing (80:20).

b. Pemodelan XGBoost

XGBoost (*Extreme Gradient Boosting*) merupakan algoritma berbasis gradient boosting yang sangat efisien dan dirancang untuk kecepatan serta performa tinggi [5]. XGBoost bekerja dengan teknik boosting yang secara iteratif memperbaiki kesalahan prediksi dari model sebelumnya, sehingga memiliki performa lebih baik dalam menangani dataset besar dan kompleks dibandingkan metode regresi tradisional [6]. XGBoost menggunakan pendekatan *gradient boosting*, di mana model *decision tree* dibangun secara bertahap dan hasil akhirnya merupakan kombinasi dari semua pohon keputusan yang telah dilatih dalam beberapa iterasi. Model ini dioptimalkan untuk kecepatan dan efisiensi memori, serta mendukung berbagai fungsi loss yang dapat disesuaikan dengan kebutuhan pengguna. Pada penelitian ini pemodelan XGBoost diterapkan menggunakan pustaka xgboost dengan fungsi `xgb.XGBRegressor()`. Model ini dilatih menggunakan `fit()` pada data training dan diuji dengan `predict()` pada data testing. XGboost menggunakan pembagian dataset menjadi data training dan data testing dengan rasio 80:20 menggunakan `train_test_split`.

c. Pemodelan LightGBM

LightGBM adalah sebuah kerangka kerja berbasis algoritma GBDT yang mendukung pelatihan paralel yang efisien. LightGBM menggunakan pendekatan *leaf-wise*, di mana cabang pohon ditumbuhkan dari daun yang memberikan pengurangan loss terbesar [7]. Dalam penelitian *Light Gradient Boosting Machine as a Regression Method for Quantitative Structure-Activity Relationships* [8] menemukan bahwa LightGBM mampu menghasilkan prediksi seakurat jaringan saraf satu-lapisan (*single-task deep neural nets*), 1.000 kali lebih cepat daripada *Random Forest* dan sekitar 4 × lebih cepat dibanding XGBoost pada model-model berukuran besar. LightGBM juga mendukung pemrosesan paralel dan pembelajaran terdistribusi, serta menangani fitur kategorikal secara langsung tanpa perlu dilakukan encoding. Pada pemodelan LightGBM, algoritma ini diterapkan menggunakan pustaka `lightgbm` dengan fungsi `lgb.LGBMRegressor()`. Model ini juga dilatih menggunakan `fit()`

dan diuji dengan predict (), serupa dengan XGBoost. Begitu juga dengan pembagian dataset menjadi data training dan data testing yakni dengan rasio 80:20 menggunakan train_test_split.

Untuk memperoleh performa model yang optimal, dilakukan pemilihan parameter pada masing-masing algoritma. Rincian parameter yang digunakan ditampilkan pada **Tabel 3** dan **Tabel 4**.

Tabel 3. Parameter Model XGBoost

Parameter	Nilai
n_estimators	200.00
learning_rate	0.05
max_depth	6.00
colsample_bytree	0.80
subsample	0.80
gamma	0.10
reg_alpha	0.10
reg_lambda	0.10
random_state	42.00

Tabel 4. Parameter Model LightGBM

Parameter	Nilai
n_estimators	200.00
learning_rate	0.05
max_depth	6.00
colsample_bytree	0.80
subsample	0.80
reg_alpha	0.10
reg_lambda	0.10
random_state	42.00

Berdasarkan **Tabel 3**. Dalam pemodelan XGBoost, parameter utama seperti n_estimators menentukan jumlah pohon, learning_rate mengontrol kontribusi tiap iterasi, dan max_depth membatasi kedalaman pohon untuk menghindari overfitting. colsample_bytree dan subsample membantu mengurangi kompleksitas model, sementara gamma, reg_alpha, dan reg_lambda berperan dalam regularisasi. random_state memastikan hasil yang konsisten. Sementara itu, pada **Tabel 4**. LightGBM menggunakan parameter serupa subsample dan colsample_bytree digunakan untuk mengurangi overfitting, sedangkan reg_alpha dan reg_lambda membantu dalam regularisasi. random_state juga diterapkan untuk memastikan replikasi hasil model.

2.4 Evaluasi Model

Dalam evaluasi kinerja model, pada penelitian ini digunakan beberapa metrik yang membantu menilai seberapa baik model mampu memprediksi data dengan akurat. Metrik-metrik ini memberikan gambaran tentang seberapa besar kesalahan prediksi serta sejauh mana model dapat menjelaskan variasi dalam data. Beberapa metrik utama yang digunakan dalam analisis ini adalah RMSE, MAE, MSE dan koefisien determinasi (R^2). Berikut adalah penjelasan masing-masing metrik tersebut.

a. Mean Squared Error (MSE)

MSE digunakan untuk menilai kualitas suatu model dalam analisis regresi. Metrik ini mengukur rata-rata kuadrat dari kesalahan prediksi terhadap nilai aktual [9]. Semakin kecil nilai MSE, semakin baik model dalam memprediksi data dengan sedikit kesalahan. Nilai

MSE dapat dihitung dengan persamaan sebagai berikut:

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (1)$$

b. Mean Absolute Error (MAE)

MAE digunakan untuk mengukur akurasi model regresi dengan menghitung rata-rata selisih absolut antara nilai aktual dan nilai prediksi [9]. MAE memberikan gambaran langsung tentang seberapa besar rata-rata kesalahan prediksi model tanpa memperhitungkan arah kesalahan (positif atau negatif). Nilai MAE dapat dihitung dengan persamaan sebagai berikut:

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (2)$$

c. Koefisien Determinasi (R^2)

R^2 adalah nilai antara 0 hingga 1 (atau 0 hingga 100 dalam persen) yang menunjukkan seberapa baik variabel independen dalam menjelaskan variasi variabel dependen [9]. Nilai R^2 mendekati 1 menunjukkan bahwa model memiliki kemampuan prediksi yang baik, sedangkan nilai mendekati 0 menunjukkan bahwa model kurang dapat menjelaskan variasi dalam data. Nilai R^2 dapat dihitung dengan persamaan sebagai berikut:

$$R^2 = 1 - \frac{\sum (\hat{y}_i - y_i)^2}{\sum (\bar{y}_i - y_i)^2} \quad (3)$$

d. Root Mean Square Error (RMSE)

RMSE digunakan untuk mengukur seberapa besar kesalahan prediksi model regresi dalam satuan yang sama dengan variabel target. Jika RMSE mendekati 0, artinya model memiliki performa yang baik dengan kesalahan prediksi yang kecil, sedangkan jika RMSE mendekati 1, artinya kesalahan prediksi model relatif kecil tetapi masih ada deviasi yang bisa diperbaiki [9]. Nilai RMSE dapat dihitung dengan persamaan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum (X - Y)^2}{n}} \quad (4)$$

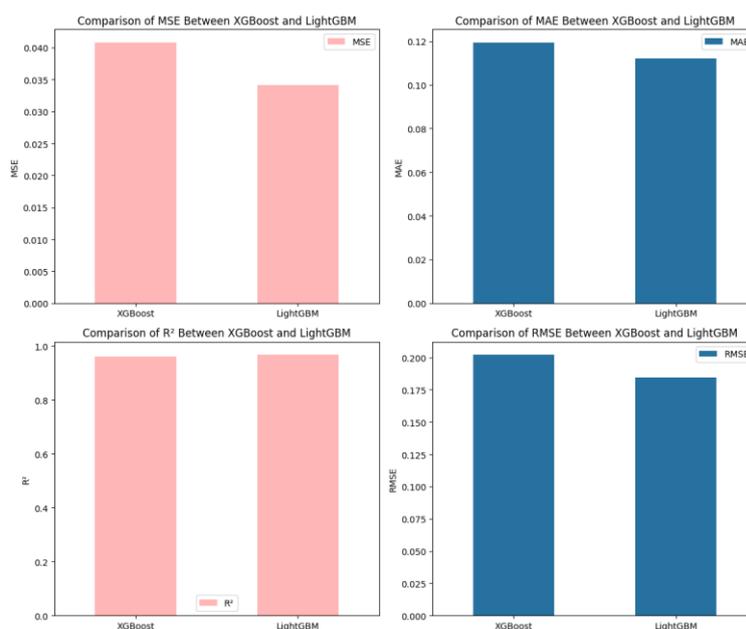
3. Hasil dan Diskusi

Setelah melalui beberapa tahapan dalam proses pemodelan dan pengujian, diperoleh hasil evaluasi kinerja dari algoritma yang digunakan. Evaluasi ini dilakukan menggunakan beberapa metrik utama, yaitu RMSE, MAE, MSE dan koefisien determinasi (R^2). Metrik-metrik ini memberikan gambaran tentang sejauh mana model dapat memprediksi data dengan akurat serta mengukur tingkat kesalahan yang dihasilkan. Hasil perbandingan XGBoost dan LightGBM dapat dilihat pada **Tabel 5**.

Table 5. Hasil perbandingan XGBoost dan LightGBM

Algoritma	MSE	MAE	R ²	RMSE
XGBoost	0.0408	0.1194	0.9596	0.2021
LightGBM	0.0341	0.1120	0.9663	0.1847

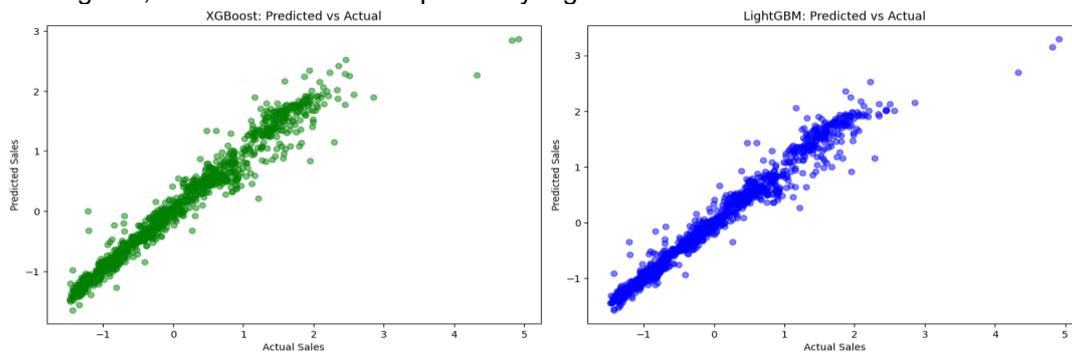
Analisis komparatif terhadap algoritma XGBoost dan LightGBM dalam konteks prediksi variabel penjualan menunjukkan bahwa kedua model memiliki performa yang sangat baik, dengan keunggulan yang konsisten ditunjukkan oleh LightGBM. Berdasarkan **Tabel 5**, algoritma LightGBM mencatatkan nilai *Mean Squared Error* (MSE) sebesar 0.0341, yang lebih rendah dibandingkan dengan XGBoost yang memiliki MSE sebesar 0.0408. Hal serupa terlihat pada nilai *Mean Absolute Error* (MAE), di mana LightGBM memperoleh 0.1120, lebih baik dibandingkan XGBoost dengan MAE sebesar 0.1194. Selain itu, koefisien determinasi (R²) LightGBM mencapai 0.9663, sedikit lebih tinggi dibandingkan nilai 0.9596 pada XGBoost, yang mengindikasikan kemampuan LightGBM dalam menjelaskan variabilitas data target dengan lebih akurat. *Nilai Root Mean Squared Error* (RMSE) pada LightGBM juga lebih rendah, yaitu 0.1847, dibandingkan dengan 0.2021 pada XGBoost. Secara keseluruhan, hasil ini menunjukkan bahwa LightGBM memberikan performa prediksi yang lebih unggul dengan tingkat kesalahan yang lebih rendah dibandingkan XGBoost. Gambar hasil visualisasi evaluasi model dapat dilihat pada **Gambar 6**.



Gambar 6. Visualisasi Hasil

Seperti yang terlihat pada **Gambar 6** LightGBM memiliki nilai MSE dan MAE yang sedikit lebih rendah dibandingkan XGBoost. Hal ini menunjukkan bahwa LightGBM mampu menghasilkan prediksi dengan tingkat kesalahan kuadrat rata-rata dan kesalahan absolut yang lebih kecil. Selain itu, nilai R² dari LightGBM sedikit lebih tinggi, yang berarti model ini mampu menjelaskan variabilitas data target dengan lebih baik dibandingkan XGBoost. Sementara itu, nilai RMSE dari LightGBM juga lebih rendah, yang mengindikasikan bahwa model ini menghasilkan kesalahan prediksi yang lebih kecil dalam satuan asli data. Secara keseluruhan, hasil evaluasi menunjukkan bahwa LightGBM memiliki kinerja yang lebih baik dibandingkan XGBoost dalam tugas regresi pada data yang digunakan. Meskipun perbedaan performa antara kedua model tidak terlalu signifikan secara visual, konsistensi keunggulan LightGBM dalam semua metrik evaluasi menunjukkan bahwa algoritma ini lebih optimal dan efisien dalam menghasilkan prediksi yang akurat. Untuk memahami sejauh mana akurasi prediksi dari masing-masing model, juga

dilakukan visualisasi hasil prediksi terhadap nilai aktual dalam bentuk scatter plot. Grafik pada **Gambar 7.** berikut menunjukkan hubungan antara nilai aktual (*actual sales*) dan nilai prediksi (*predicted sales*) pada model XGBoost dan LightGBM. Semakin dekat titik-titik tersebut terhadap garis diagonal, maka semakin akurat prediksi yang dihasilkan oleh model



Gambar 7. Plot Sebaran Nilai Aktual dan Prediksi

Seperti yang terlihat pada **Gambar 7** Scatter plot sebelah kiri menampilkan hubungan antara nilai aktual dan hasil prediksi dari model XGBoost, sedangkan scatter plot sebelah kanan menggambarkan kinerja model LightGBM. Pola distribusi titik data yang berada di sekitar garis diagonal menunjukkan bahwa kedua algoritma mampu menghasilkan estimasi yang mendekati nilai aktual dengan tingkat akurasi yang tinggi.

4. Kesimpulan

Penelitian ini telah berhasil menganalisis dan membandingkan performa algoritma XGBoost dan LightGBM dalam konteks prediksi penjualan ritel menggunakan dataset Walmart Store Sales. Hasil evaluasi menunjukkan bahwa LightGBM memiliki performa yang lebih unggul dibandingkan XGBoost dalam seluruh metrik evaluasi yang digunakan. Meskipun perbedaannya relatif kecil, keunggulan konsisten LightGBM menunjukkan bahwa algoritma ini lebih optimal untuk implementasi pada kasus prediksi penjualan Walmart. Selain itu, analisis feature importance mengungkapkan bahwa variabel Store memiliki pengaruh dominan dalam model prediktif, yang mengindikasikan bahwa karakteristik lokasi toko merupakan faktor utama dalam dinamika penjualan. Sebaliknya, variabel ekonomi seperti Fuel Price menunjukkan kontribusi yang lebih kecil dalam model. Berdasarkan temuan ini, direkomendasikan agar Walmart mengimplementasikan model LightGBM dalam sistem prediksi penjualannya dengan mempertimbangkan faktor-faktor yang berkaitan dengan karakteristik toko. Penelitian lebih lanjut dapat memperluas fitur dataset, termasuk data promosi, demografi konsumen, dan dinamika kompetitif pasar, serta melakukan hyperparameter tuning yang lebih mendalam untuk meningkatkan akurasi model. Evaluasi dan pembaruan model secara berkala juga sangat direkomendasikan untuk mengakomodasi perubahan tren konsumen dan dinamika pasar yang terus berkembang.

Daftar Pustaka

- [1] A. Ramadhan, H. Suryanto, dan D. Prasetyo, "Prediksi Penjualan Menggunakan Algoritma C4.5 pada Data Historis Walmart," *E-Journal PPPMITPA*, 2024.
- [2] R. Tombeng dan H. Ardian, "Peramalan Penjualan Menggunakan Model LSTM pada Data Transaksi Ritel Supermarket Taiwan," *Cogito*, vol. 5, no. 2, pp. 45–52, 2021.
- [3] A. Winurputra dan S. Ratnawati, "Implementasi XGBoost dalam Peramalan Penjualan Produk Ritel Menggunakan CRISP-DM," *Jurnal Teknologi Informasi*, vol. 10, no. 1, pp. 33–41, 2024.
- [4] J. Xie, Y. Wang, dan Z. Liu, "Enhancing Retail Sales Forecasting with Hybrid LSTM and LightGBM Models," *ResearchGate*, 2021.
<https://www.researchgate.net/publication/356994527>
- [5] Dewi, F. S., & Dewayanto, T. (2024). Peran big data analytics, machine learning, dan

- artificial intelligence dalam pendeteksian financial fraud: A systematic literature review. *Diponegoro Journal of Accounting*, 13(3).
- [6] L. W. Rizkallah, "Enhancing the performance of gradient boosting trees on regression problems," *Journal of Big Data*, vol. 12, no. 35, 2025.
<https://journalofbigdata.springeropen.com/articles/10.1186/s40537-025-01071-3>
- [7] Wardhana, I., Ariawijaya, M., Isnaini, V. A., & Wirman, R. P. (2022). Gradient Boosting Machine, Random Forest dan Light GBM untuk Klasifikasi Kacang Kering. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(1), 92-99.
- [8] Sheridan, R. P., Wang, W. M., Liaw, A., Ma, J., & Gifford, E. M. (2021). Light Gradient Boosting Machine as a regression method for quantitative structure–activity relationships. *arXiv preprint arXiv:2105.08626*. <https://arxiv.org/abs/2105.08626>
- [9] Hodson, D. (2022). *Understanding RMSE, MSE, and MAE in model evaluation*. *Geoscientific Model Development Discussions*. Copernicus Publications. <https://gmd.copernicus.org/preprints/gmd-2022-64/gmd-2022-64.pdf>

Halaman ini sengaja dibiarkan kosong