

Optimasi Waktu dan Besaran Diskon Produk *Slow-moving* Berdasarkan Prediksi Penjualan dengan Model Prophet: Studi Kasus Toko Rumahbayitaz

Azka Chanda Milanesta
Fakultas Rekayasa Industri
Telkom University
Bandung, Indonesia

azkachandam@student.telkomuniversit
y.ac.id

Irfan Darmawan
Fakultas Rekayasa Industri
Telkom University
Bandung, Indonesia

irfandarmawan@telkomuniversity.ac.id

Oktariani Nurul Pratiwi
Fakultas Rekayasa Industri
Telkom University
Bandung, Indonesia

onurulp@telkomuniversity.ac.id

Abstrak — *Pertumbuhan e-commerce di Indonesia menuntut pelaku usaha untuk menyusun strategi promosi yang lebih terukur, khususnya dalam mengatasi produk slow-moving yang dapat menurunkan performa penjualan. Penelitian ini bertujuan untuk menganalisis tren historis penjualan di Toko Rumahbayitaz, menerapkan model time series Prophet untuk memprediksi performa produk slow-moving, serta merancang strategi diskon berbasis hasil prediksi. Permasalahan yang diangkat meliputi belum adanya sistem prediksi penjualan yang akurat, kurangnya analisis historis waktu pemberian diskon, dan ketiadaan mekanisme perencanaan promosi berbasis data. Penelitian ini menggunakan pendekatan Knowledge Discovery in Databases (KDD) dengan algoritma Prophet dan data penjualan harian periode Januari 2023 hingga April 2024 dari Shopee Seller Centre. Hasil menunjukkan bahwa Prophet mampu mengidentifikasi pola musiman mingguan dan bulanan serta memberikan prediksi akurat untuk mendeteksi periode dengan permintaan rendah. Strategi diskon seperti “Midweek Deal” dan “Flash sale Minggu Ceria” disusun berdasarkan output model dan menunjukkan potensi dalam meningkatkan efektivitas promosi. Kesimpulannya, integrasi model Prophet dalam perencanaan strategi diskon memungkinkan toko merancang promosi yang lebih relevan, tepat waktu, dan berbasis pola permintaan konsumen.*

Kata kunci— *diskon, e-commerce, forecasting, penjualan, Prophet, Shopee, slow-moving, time series*

I. PENDAHULUAN

Pertumbuhan pesat *e-commerce* di Indonesia telah mengubah pola konsumsi masyarakat. Shopee mencatat dominasi pasar dengan 127,4 juta kunjungan per bulan selama 2023 [1], menciptakan persaingan tinggi antar penjual. Dalam konteks ini, Toko Rumahbayitaz penjual produk ibu dan anak di Shopee mengalami fluktuasi penjualan signifikan antara Januari 2023 hingga Desember 2024, dengan rata-rata hanya 1–3 pesanan harian di awal tahun dan puncak hingga 7–8 pesanan per hari. Selain itu, ditemukan ketimpangan distribusi penjualan dari 26 produk yang ditawarkan, dengan sejumlah produk tergolong *slow-moving*.

Kondisi ini menyebabkan penumpukan stok, terikatnya modal, serta penurunan performa toko di algoritma sistem Shopee. Strategi diskon yang diterapkan masih bersifat intuitif dan reaktif, tanpa landasan prediktif atau analisis dampak kuantitatif terhadap profitabilitas.

Permasalahan yang diidentifikasi meliputi: (1) belum tersedianya sistem peramalan penjualan untuk produk *slow-moving*; (2) kurangnya pemanfaatan data historis dalam penjadwalan diskon; dan (3) belum adanya simulasi untuk mengukur pengaruh diskon terhadap penjualan dan margin.

Untuk menjawab permasalahan tersebut, penelitian ini menggunakan algoritma Prophet model *time series* dari Facebook yang dirancang untuk menangani tren non-linier, musiman, *outlier*, dan data tidak teratur dengan pendekatan aditif [2]. Prophet terbukti lebih akurat dan efisien dibanding model tradisional seperti ARIMA [3], serta efektif digunakan dalam konteks penjualan ritel di Indonesia [4].

Penelitian ini bertujuan untuk mengembangkan strategi diskon berbasis prediksi penjualan produk *slow-moving* di Toko Rumahbayitaz dengan pendekatan Prophet. Metode ini diharapkan dapat meningkatkan efektivitas promosi, menurunkan stagnasi stok, serta mengoptimalkan profit secara berkelanjutan melalui sistem pendukung keputusan berbasis data.

II. KAJIAN TEORI

A. Penjualan Produk di *E-commerce*

meningkatkan efisiensi dan fleksibilitas, tetapi juga memperluas jangkauan pasar. Strategi dalam *e-commerce* seperti promosi, diskon, ulasan pelanggan, dan tampilan visual produk telah mengubah pola konsumsi masyarakat [5]. Dalam konteks ini, beberapa aspek yang turut memengaruhi keberhasilan penjualan meliputi kualitas informasi produk yang disampaikan, daya tarik visual seperti foto dan video, keefektifan strategi promosi dan diskon berbasis data historis, kekuatan ulasan serta *rating* konsumen dalam membangun

kepercayaan, serta kecepatan dan kualitas respons penjual terhadap konsumen [6].

B. Produk *Slow-Moving*

Produk *slow-moving* adalah produk dengan perputaran rendah dalam periode tertentu. FSN (*Fast-moving, Slow-moving, Non-moving*) berbasis *Turn Over Ratio* (TOR) merupakan metode yang umum digunakan dalam klasifikasi produk ini. Metode ini dapat mengidentifikasi 42,42% bahan kemasan sebagai *slow-moving* dengan TOR antara 1-3 [7].

Permintaan yang tidak pasti menjadi penyebab utama *slow-moving inventory*. Studi lain mengombinasikan metode ABC, EOQ, dan turnover analysis untuk efisiensi pengelolaan stok, menghasilkan penghematan biaya hingga 24% [8]. Dalam *e-commerce* dan UMKM, integrasi digital seperti manajemen inventaris berbasis cloud dan pemisahan fisik antara produk *fast* dan *slow-moving* diperlukan untuk meminimalkan stagnasi stok [9].

C. Strategi Diskon

Diskon adalah bentuk insentif harga untuk meningkatkan volume penjualan dan mengelola stok. Diskon strategis berdasarkan data historis terbukti lebih efektif dibandingkan pendekatan acak [5]. Diskon musiman, *time-based*, dan bundling efektif jika digunakan tepat sasaran, namun bisa merusak persepsi nilai bila diterapkan berlebihan [5].

Pemilihan waktu dan jenis promosi yang tepat berpengaruh signifikan terhadap keputusan beli dan citra merek [10]. Strategi diskon berbasis data dan peramalan seperti Prophet dapat meningkatkan efisiensi dan efektivitas promosi.

D. Perilaku Konsumen dalam Pembelian Online

Perilaku konsumen dipengaruhi oleh psikologis, sosial, dan pengalaman pengguna. Interaktivitas, informativitas, dan kesenangan dapat memicu pembelian impulsif dan membangun loyalitas [11].

Kepercayaan terhadap platform, persepsi risiko, dan norma sosial juga memengaruhi keputusan beli [12]. Dalam sektor otomotif *e-commerce*, niat beli dipengaruhi oleh kepercayaan dan persepsi manfaat. Selain itu, sikap konsumen, kualitas layanan dan produk, serta kepercayaan adalah penentu utama keputusan beli [13].

E. Sales Forecasting

Peramalan penjualan adalah proses memprediksi volume penjualan masa depan berdasarkan data historis, tren, dan variabel eksternal. Digunakan dalam perencanaan produksi, pengelolaan stok, dan strategi pemasaran.

Sebuah sistem prediksi yang mengaitkan variabel eksternal dengan volume penjualan menggunakan regresi linier multivariat [14]. Metode *time series* seperti *moving average* dan *triple exponential smoothing* digunakan untuk data dengan pola musiman dan tren [15].

F. Model *Time series* Prophet

Prophet adalah model *time series* adaptif yang dikembangkan oleh Facebook [16]. Model ini terdiri dari tiga komponen utama: tren jangka panjang, musiman, efek hari libur, serta *noise*. Prophet unggul dalam interpretabilitas, ketahanan terhadap *outlier*, dan fleksibilitas penyesuaian parameter seperti libur nasional dan intervensi promosi.

Asumsi dasar dari model ini mencakup anggapan bahwa pola musiman bersifat tetap dari waktu ke waktu, tren dapat dimodelkan secara linear maupun logistik sesuai karakteristik data, dan efek hari libur dapat dikenali dan dipisahkan dari pola reguler. Selain itu, Prophet mengasumsikan bahwa residual atau selisih antara prediksi dan nilai aktual bersifat *white noise*, serta data harus memiliki interval waktu yang konsisten. Dalam konteks *e-commerce*, Prophet menunjukkan kinerja yang kompetitif jika dibandingkan dengan model-model lain seperti ARIMA dan LSTM, terutama karena keunggulannya dalam aspek visualisasi hasil prediksi dan efisiensi dalam proses konfigurasi model [17].

G. Metode Evaluasi Model Prediksi

Evaluasi performa model prediksi dilakukan menggunakan tiga metrik utama yang saling melengkapi untuk memberikan gambaran yang komprehensif. Mean Absolute Error (MAE) digunakan untuk mengukur rata-rata kesalahan absolut antara nilai hasil prediksi dan nilai aktual, yang mencerminkan seberapa jauh prediksi menyimpang tanpa memperhitungkan arah kesalahan [18]. Selain itu, *Root Mean Square Error* (RMSE) diaplikasikan untuk memberikan penalti yang lebih besar terhadap kesalahan prediksi yang besar, sehingga lebih sensitif terhadap *outlier* dan sangat berguna ketika kesalahan besar perlu diwaspadai [19]. Metrik ketiga, yaitu *Symmetric Mean Absolute Percentage Error* (SMAPE), digunakan untuk mengukur kesalahan dalam bentuk persentase yang bersifat simetris, dengan rentang antara 0 hingga 200 persen, sehingga memungkinkan perbandingan antar model dalam konteks skala yang berbeda [19]. Kombinasi dari ketiga metrik ini memberikan evaluasi yang lebih menyeluruh terhadap akurasi dan keandalan model prediksi yang digunakan.

H. Knowledge Discovery in Databases (KDD)


Knowledge Discovery in Databases (KDD) merupakan proses sistematis dan iteratif yang digunakan untuk mengekstraksi pengetahuan yang valid dan bermanfaat dari kumpulan data yang besar. Proses ini mencakup beberapa tahap penting yang berjalan secara berurutan dan saling terkait, mulai dari seleksi data, pra-proses data, transformasi data, penerapan teknik data mining, hingga tahap evaluasi dan interpretasi pola yang ditemukan [20]. Proses KDD berperan penting dalam mendukung pengambilan keputusan yang lebih presisi dengan cara mengidentifikasi tren tersembunyi, pola perilaku konsumen, serta mendukung sistem rekomendasi yang adaptif [21]. Dalam konteks *e-commerce*, integrasi metode KDD dengan teknik peramalan seperti Prophet memungkinkan penyusunan strategi promosi yang berbasis data dan responsif terhadap dinamika pasar.

III. METODE

Penelitian ini menggunakan pendekatan *Knowledge Discovery in Databases* (KDD) sebagai kerangka penyelesaian masalah dalam analisis data penjualan dan perancangan strategi diskon berbasis prediksi penjualan. KDD merupakan suatu proses sistematis dan terstruktur yang bertujuan untuk mengekstraksi pengetahuan yang valid, bermanfaat, dan dapat diinterpretasikan dari himpunan data yang besar, khususnya dalam konteks pengambilan keputusan berbasis data [24]. KDD tidak hanya menekankan proses teknis analisis data, tetapi juga fokus pada bagaimana

hasil yang diperoleh dapat diimplementasikan secara nyata dalam lingkungan bisnis atau organisasi.

Dalam konteks penelitian ini, pendekatan KDD diterapkan untuk menganalisis data historis penjualan dari toko Rumahbayitaz di platform Shopee, dengan tujuan utama merancang strategi diskon yang relevan terhadap produk-produk *slow-moving*. Strategi tersebut dirancang berdasarkan hasil prediksi penjualan menggunakan model deret waktu Prophet, sehingga keputusan bisnis yang diambil dapat lebih tepat sasaran dan berbasis bukti empiris. Gambar berikut menunjukkan diagram alur tahapan proses KDD yang digunakan sebagai dasar metodologi dalam penelitian ini.



Gambar III-1 Metode KDD

A. Pengumpulan Data

Tahap awal dalam proses KDD adalah pengumpulan data historis penjualan yang diperoleh dari toko Rumahbayitaz di Shopee. Data yang dihimpun mencakup jumlah penjualan harian per produk, tanggal transaksi, dan informasi kategori atau nama produk. Dataset ini berasal dari sistem digital platform *e-commerce* dan akan menjadi landasan utama dalam proses analisis deret waktu untuk keperluan peramalan.

B. Pra-pemrosesan Data

Setelah data terkumpul, tahap selanjutnya adalah pra-pemrosesan yang bertujuan untuk menyaring dan membersihkan data dari potensi gangguan analisis. Proses ini meliputi penghapusan duplikasi, penanganan missing values, koreksi format tanggal yang tidak konsisten, serta seleksi terhadap entri yang tidak relevan. Normalisasi data juga dilakukan untuk memastikan keseragaman format dan struktur data, sehingga model peramalan dapat bekerja secara optimal.

C. Transformasi Data

Data yang telah bersih kemudian ditransformasi ke dalam format deret waktu agar sesuai dengan input yang dibutuhkan oleh model Prophet. Transformasi ini dilakukan dengan menyusun data berdasarkan tanggal dan volume penjualan per produk. Jika diperlukan, agregasi data dilakukan dari level harian menjadi mingguan atau bulanan guna menangkap pola musiman dan tren jangka panjang secara lebih signifikan. Proses ini memungkinkan deteksi terhadap fluktuasi musiman dan tren penurunan penjualan secara sistematis.

D. Proses Data Mining

Tahap inti dari proses KDD dalam penelitian ini adalah penerapan teknik data mining berupa peramalan penjualan menggunakan model Prophet. Model ini menganalisis tren jangka panjang, komponen musiman, serta potensi pengaruh dari hari libur terhadap volume penjualan masa depan. Hasil prediksi digunakan untuk mengidentifikasi produk-produk yang menunjukkan potensi penurunan penjualan pada periode tertentu, yang selanjutnya akan menjadi dasar dalam merancang strategi diskon yang lebih terarah dan efisien.

E. Evaluasi dan Interpretasi Hasil

Setelah proses pemodelan selesai, dilakukan evaluasi performa model untuk mengukur tingkat akurasi prediksi yang dihasilkan. Metrik yang digunakan dalam evaluasi ini mencakup *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE), yang membantu menilai deviasi antara hasil prediksi dengan data aktual. Selanjutnya, hasil prediksi diinterpretasikan untuk mendukung keputusan diskon strategis, khususnya pada produk-produk *slow-moving* dan pada periode waktu yang secara prediktif mengalami penurunan permintaan. Visualisasi grafik hasil peramalan turut digunakan dalam tahap ini sebagai alat bantu untuk memperjelas pola yang terbentuk dan mempermudah proses pengambilan keputusan.

IV. HASIL DAN PEMBAHASAN

A. Seleksi Data

Pada tahap awal proses *Knowledge Discovery in Databases* (KDD), dilakukan seleksi data sebagai fondasi dalam membangun model peramalan penjualan dengan algoritma *time series* Prophet. Dataset yang digunakan diperoleh dari Shopee Seller Center milik Toko RumahBayiTAZ, mencakup 1.125 transaksi penjualan periode Januari 2023 hingga April 2024, terdiri atas 49 atribut.

Data diekspor dalam format .xlsx, kemudian ditelaah berdasarkan struktur dan kelengkapan atributnya. Proses seleksi mempertimbangkan prinsip data relevancy dan data lineage, dengan fokus pada informasi yang memiliki keterkaitan langsung terhadap dinamika waktu dan volume penjualan. Dua atribut utama dipilih untuk konstruksi model, yaitu “Waktu Pesanan Dibuat” sebagai penanda temporal (ds) dan “Jumlah” sebagai target (y).

Selanjutnya, dua atribut tambahan dipilih sebagai variabel pendukung. “Nama Produk” digunakan untuk pemetaan tren per SKU (*Stock Keeping Unit*), sedangkan “Harga Awal” memberikan konteks dalam melihat korelasi harga terhadap volume pembelian. Keempat atribut tersebut dikelompokkan berdasarkan fungsinya terhadap model dan ditampilkan pada Tabel 1 berikut.

Tabel IV-1 Deskripsi Atribut Terpilih

Kolom Dataset	Deskripsi	Kategori Atribut
Nama Produk	Nama produk yang dipesan oleh konsumen	G (Grouping)
Waktu Pesanan Dibuat	Tanggal dan waktu saat pesanan dilakukan oleh konsumen	S (Sequence)
Harga Awal	Harga asli produk sebelum potongan diskon	H (Helper)
Jumlah	Jumlah unit produk yang dipesan dalam satu transaksi	Y (Target)

Secara keseluruhan, hasil seleksi ini menunjukkan bahwa struktur dataset memiliki kelengkapan yang cukup untuk pemodelan Prophet, meskipun hanya sebagian kecil dari atribut yang digunakan secara langsung dalam algoritma. Pendekatan ini didasarkan pada prinsip parsimoni model, yakni menjaga kompleksitas model serendah mungkin tanpa mengorbankan performa prediktif.

Temuan ini menunjukkan bahwa atribut transaksi dasar, khususnya waktu dan jumlah penjualan, sudah cukup untuk menangkap dinamika perilaku konsumen dari waktu ke waktu, khususnya dalam konteks *e-commerce* dengan pola musiman yang khas. Hal ini sejalan dengan struktur Prophet yang dirancang untuk menangkap komponen tren, musiman, dan efek liburan secara terpisah.

B. Pra-pemrosesan Data

Pra-pemrosesan merupakan tahap fundamental dalam pendekatan *Knowledge Discovery in Databases* (KDD) yang bertujuan untuk memastikan bahwa data bersih, terstruktur, dan sesuai untuk pemodelan prediktif. Pada penelitian ini, data transaksi dari Toko RumahBayiTAZ yang diperoleh dari Shopee Seller Center menjalani serangkaian tahapan pembersihan, standarisasi, dan transformasi agar dapat digunakan sebagai input dalam model *time series* Prophet.

Langkah pertama adalah deteksi dan penghapusan duplikasi data berdasarkan kolom "No. Pesanan" sebagai identifier unik. Dari total 1.125 baris awal, sebanyak 275 baris teridentifikasi sebagai duplikat dan dihapus, menghasilkan 850 baris data unik. Proses ini dirangkum dalam Tabel 2 berikut:

Tabel IV-2 Hasil Penghapusan Duplikasi

Keterangan	Jumlah Baris
Total Data Awal	1.125
Jumlah Data Duplikat	275
Jumlah Data Setelah Filter	850

Selanjutnya, kolom "Nama Produk" dibersihkan dari unsur non-informatif seperti lokasi ("Depok"), frasa promosi ("original", "babyshop"), dan kata berlebihan lainnya menggunakan daftar stopword. Untuk mengkonsolidasikan variasi nama produk yang semantik namun berbeda secara tekstual, digunakan metode fuzzy matching dengan token_sort_ratio. Proses ini menghasilkan penggabungan nama-nama produk yang memiliki kemiripan $\geq 70\%$. Contoh pasangan nama produk dengan skor kemiripan tinggi disajikan dalam Tabel 3.

Tabel IV-3 Skor Kemiripan Nama Produk (Fuzzy Matching)

Nama Produk 1	Nama Produk 2	Skor Kemiripan
gift set parcel baju celana jumper topi	parcel baby gift set baju celana jumper topi	93.98%
100% walker dorong belajar jalan minicar	minicar walker dorong belajar jalan	93.33%
baju set celana jumper topi sepatu	baju set import celana jumper topi sepatu	90.67%
kursi goyang bouncer rocker chair	kursi goyang bouncer rocker	90.00%
piano playmat	my piano playmat	89.66%

Hasil dari proses tersebut memperlihatkan perbedaan signifikan antara nama produk mentah dan nama yang telah dibersihkan. Contoh perbandingan ditunjukkan dalam Tabel 4.

Tabel IV-4 Nama Produk Sebelum dan Sesudah Pembersihan

Sebelum Dibersihkan	Setelah Dibersihkan
100% Original Sugar Baby Walker mainan dorong edukasi belajar jalan toko Depok	100% walker dorong belajar jalan minicar
8in1 Gift Set Parcel bayi import kemasan tile kado bayi baju set jumper slaber	baju set celana jumper topi sepatu

Untuk mendukung analisis temporal, kolom "Waktu Pesanan Dibuat" diekstraksi menjadi fitur granular: jam, hari, tanggal, bulan, tahun, dan penanda akhir pekan. Ekstraksi ini menghasilkan fitur-fitur yang kaya untuk analisis musiman dan deteksi pola pembelian berdasarkan waktu. Hasilnya disajikan dalam Tabel 5.

Tabel IV-5 Format Waktu Sebelum dan Sesudah Ekstraksi


Waktu Asli	Jam	Hari	Tanggal	Bulan	Tahun
2024-02-10 11:58:00	11	Saturday	2024-02-10	2	2024
2023-01-26 17:08:00	17	Thursday	2023-01-26	1	2023

Selain itu, dilakukan deteksi *outlier* pada variabel numerik menggunakan metode Interquartile Range (IQR). Kolom "Jumlah" mengandung 26 *outlier* yang berada di luar rentang -2 hingga 6 dan dihapus. Ringkasan statistik disajikan dalam Tabel 6, dan visualisasi distribusi *outlier* sebelum dan sesudah ditampilkan pada Gambar 2.

Tabel IV-6 Statistik Deteksi *Outlier* Kolom "Jumlah"

Statistik	Nilai
Q1	1.0
Q3	3.0
IQR	2.0
Lower Bound	-2.0
Upper Bound	6.0
Jumlah <i>Outlier</i>	26

Perbandingan Box Plot Kolom "Jumlah"



Gambar IV-1 Boxplot Kolom "Jumlah" Sebelum dan Sesudah Pembersihan *Outlier*


Untuk menyesuaikan data ke format Prophet, data transaksi diubah menjadi agregat harian. Total penjualan dihitung dari

hasil perkalian "Harga Awal" dan "Jumlah". Hasil agregasi ini disajikan dalam Tabel 7.

Tabel IV-7 Contoh Hasil Agregasi Penjualan Harian

Tanggal	Jumlah Pesanan	Total Penjualan
2023-01-01	1	169.000
2023-01-02	1	109.500
2023-01-10	3	87.600
2023-01-11	2	109.500

Distribusi total penjualan harian bersifat skewed ke kanan, sehingga untuk menstabilkan variansi dan mendukung generalisasi model, diterapkan transformasi logaritmik menggunakan fungsi $\log_{1p}()$. Hasil transformasi membuat distribusi lebih simetris. Perbandingan visual sebelum dan sesudah transformasi ditampilkan dalam Gambar 3.



Gambar IV-2 Distribusi Total Penjualan Sebelum dan Sesudah Transformasi Log1p

C. Transformasi Data

Transformasi data merupakan tahap lanjutan dalam alur *Knowledge Discovery in Databases* (KDD) setelah proses seleksi dan pra-pemrosesan selesai dilakukan. Tujuan dari tahap ini adalah menyiapkan data dalam format yang sesuai dengan kebutuhan model deret waktu Prophet, baik dari segi struktur, semantik, maupun informatifitas temporal. Transformasi ini mencakup tiga aspek utama: konversi format deret waktu, rekayasa fitur berbasis waktu, dan pembagian data untuk pelatihan dan pengujian model.

Agar data transaksi penjualan harian dapat diproses oleh Prophet, struktur data harus disesuaikan ke dalam dua kolom utama: *ds* (*datestamp*) sebagai penanda waktu dan *y* sebagai target variabel atau nilai yang diprediksi. Proses konversi ini dilakukan dengan mengelompokkan data berdasarkan tanggal dan menjumlahkan nilai penjualan atau jumlah transaksi per hari. Hasil konversi menghasilkan format *time series* yang memudahkan identifikasi pola tren jangka panjang dan musiman. Contoh struktur hasil konversi ditampilkan dalam Tabel 8 berikut:

Tabel IV-8 Contoh Struktur Data *Time series* untuk Prophet


ds	y
2023-01-01	1
2023-01-02	5
2023-01-09	1

Untuk memperkuat model prediksi, dilakukan penambahan fitur berbasis waktu yang mencerminkan faktor musiman eksplisit. Fitur-fitur seperti indikator akhir pekan (*weekend flag*) dan penanda hari libur disisipkan ke dalam dataset sebagai komponen tambahan agar Prophet dapat menangkap fluktuasi yang disebabkan oleh perilaku konsumen spesifik terhadap waktu. Penambahan ini memperkaya dimensi temporal dan membantu model memetakan pola-pola seperti penurunan penjualan saat hari kerja atau peningkatan signifikan saat akhir pekan.

Selain itu, struktur dataset diatur agar mendukung integrasi *external regressor*, yaitu variabel eksternal seperti diskon massal, hari gajian, atau promosi Shopee seperti Harbolnas. Walaupun fitur eksternal belum diaktifkan dalam eksperimen awal, arsitektur data telah disiapkan untuk pengujian lanjutan pada pengembangan tahap berikutnya.

Data deret waktu tidak boleh dibagi secara acak karena akan merusak urutan temporal yang esensial bagi model. Oleh karena itu, digunakan pendekatan *time series split*, di mana data dibagi secara berurutan berdasarkan waktu. Proporsi pembagian mengikuti rasio umum 80:20, di mana 80% pertama digunakan sebagai data latih (*training set*) dan 20% terakhir sebagai data uji (*testing set*).

Visualisasi hasil pembagian data dapat dilihat pada Gambar 3, yang menunjukkan batas jelas antara segmen *training* dan *testing* secara kronologis. Pendekatan ini menghindari risiko data leakage serta memastikan bahwa model diuji menggunakan data masa depan yang belum pernah dilihat selama pelatihan.




Gambar IV-3 Visualisasi Pembagian Data Training dan Testing

D. Data Mining

Tahap ini merupakan pelaksanaan data mining (Tahap keempat dalam metode KDD), di mana model Prophet diaplikasikan pada data historis penjualan yang telah melalui proses prapemrosesan dan seleksi fitur. Model ini menghasilkan informasi mendalam mengenai tren, pola musiman, serta estimasi penjualan di masa depan.

Model Prophet yang digunakan dalam penelitian ini memanfaatkan informasi tanggal dan volume penjualan sebagai variabel utama, serta dilengkapi dengan fitur temporal seperti hari dalam minggu dan bulan dalam tahun untuk menangkap pola musiman.

Gambar 4 menunjukkan hasil prediksi penjualan selama periode yang ditentukan, termasuk *trend component*, *weekly seasonality*, dan *yearly seasonality* yang dihasilkan oleh model. Dari grafik tersebut, terlihat bahwa model mampu menangkap tren jangka panjang dan pola musiman yang berulang setiap minggu dan tahun.




Gambar IV-4 Hasil Prediksi Penjualan Menggunakan Model Prophet

Selain grafik prediksi, model Prophet juga menghasilkan komponen visualisasi yang mencakup tren jangka panjang, pola musiman mingguan, dan pola musiman tahunan. Seluruh komponen ini ditampilkan secara terpadu pada Gambar 5.

Pada bagian pertama, terlihat adanya peningkatan tren penjualan dalam jangka panjang, menunjukkan kecenderungan pertumbuhan penjualan seiring waktu.

Selanjutnya, pola musiman mingguan menunjukkan bahwa penjualan cenderung meningkat pada akhir pekan (Sabtu dan Minggu), sementara pada hari kerja relatif lebih rendah.

Sementara itu, pola musiman tahunan menampilkan lonjakan penjualan yang signifikan pada bulan-bulan tertentu, terutama pada bulan Desember, yang kemungkinan berkaitan dengan periode belanja akhir tahun.



Gambar IV-5 Visualisasi Komponen Tren, Musiman Mingguan, dan Musiman Tahunan Model Prophet

Model juga mengestimasi interval kepercayaan (confidence interval) pada setiap titik prediksi, yang berguna untuk mengukur ketidakpastian prediksi. Gambar 1 memperlihatkan batas atas dan bawah prediksi penjualan, yang membentuk area bayangan abu-abu. Area ini menunjukkan rentang fluktuasi yang masih dianggap wajar berdasarkan data historis. Semakin sempit area bayangan, semakin tinggi tingkat kepastian prediksi.

Berdasarkan hasil prediksi dan komponen model Prophet, ditemukan beberapa pola penting yang dapat mendukung pengambilan keputusan. Tren penjualan jangka panjang menunjukkan pertumbuhan stabil, yang menjadi dasar dalam perencanaan stok dan pengadaan. Pola musiman mingguan mengindikasikan peningkatan penjualan di akhir pekan, terutama Sabtu dan Minggu, sehingga dapat dimanfaatkan untuk promosi berbasis waktu seperti diskon akhir pekan. Selain itu, lonjakan musiman pada bulan Desember yang bertepatan dengan libur akhir tahun dapat dimaksimalkan melalui kampanye pemasaran musiman. Temuan ini

memungkinkan penjadwalan diskon produk *slow-moving* secara strategis, pengelolaan logistik yang lebih presisi, dan penyusunan promosi berbasis waktu yang efektif. Namun, seluruh insight ini masih bersifat awal dan perlu dievaluasi lebih lanjut pada tahap evaluasi dan deployment dalam proses KDD.

E. Penanganan Risiko

Tahap ini menyajikan hasil akhir dari tahapan proses *Knowledge Discovery in Databases* (KDD), yaitu tahap implementasi dan pemanfaatan model prediksi untuk mendukung pengambilan keputusan strategis. Setelah melalui tahapan sebelumnya mulai dari seleksi data, prapemrosesan, hingga pemodelan hasil yang diperoleh dari model prediktif kemudian dianalisis untuk mengidentifikasi pola, menyusun strategi diskon berbasis data, serta mengevaluasi potensi optimalisasi operasional toko. Fokus utama pembahasan ini mencakup prediksi penjualan, identifikasi produk *slow-moving*, perancangan kalender promosi, hingga simulasi strategi diskon spesifik untuk mendukung efisiensi manajemen dan peningkatan pendapatan.

Visualisasi hasil peramalan disajikan dalam Gambar 6, yang menampilkan garis biru sebagai prediksi penjualan harian serta bayangan biru yang menunjukkan interval kepercayaan sebesar 80%. Hasil prediksi memperlihatkan kecenderungan peningkatan penjualan pada awal Februari 2025, yang secara kontekstual dapat dikaitkan dengan perilaku konsumen seperti belanja awal bulan, periode gaji, atau promosi bulanan.



Gambar IV-6 Hasil Prediksi Penjualan dengan Model Prophet Selama 90 Hari

Secara umum, hasil ini mendukung asumsi adanya pola perilaku musiman yang dapat diantisipasi untuk mendukung perencanaan logistik dan strategi promosi. Temuan ini mengindikasikan bahwa keputusan bisnis dapat diarahkan secara lebih proaktif, seperti penyesuaian jadwal pengadaan barang, optimalisasi inventori, serta pelaksanaan promosi dinamis.

Untuk mendukung efisiensi manajemen inventori, dilakukan klasifikasi terhadap produk *slow-moving*, yaitu produk dengan tingkat perputaran penjualan rendah dalam enam bulan terakhir. Kriteria klasifikasi meliputi (1) total penjualan kumulatif kurang dari 5 unit, dan (2) frekuensi penjualan harian tidak melebihi 1 unit. Berdasarkan analisis ini, teridentifikasi 5 produk dengan performa penjualan terendah sebagaimana ditunjukkan pada Tabel 9.

Tabel IV-9 Daftar 5 Produk dengan Penjualan Terendah

Nama Produk	Jumlah Terjual	Harga Awal (Rp)
activity walker 100%	1	Rp 325.000

Nama Produk	Jumlah Terjual	Harga Awal (Rp)
bando set kaki bandana bunga	1	Rp 30.000
fin baby gendongan jarik boy	1	Rp 90.000
handuk mandi renang little palmerhaus	1	Rp 62.500
kursi makan 6in1 my chair k chair	1	Rp 396.000

Produk-produk ini kemudian dikategorikan ke dalam dua segmen: *slow-moving low-margin* dan *slow-moving high-margin*. Pendekatan strategi promosi yang diusulkan ditampilkan dalam Tabel 10.

Tabel IV-10 Strategi Diskon Berdasarkan Kategori Produk

Kategori	Kriteria	Strategi Diskon
<i>Slow - Low Margin</i>	Penjualan rendah, margin tipis	<i>Flash sale</i> jangka pendek
<i>Slow - High Margin</i>	Penjualan rendah, margin besar	Diskon selektif saat peak season

Analisis ini memberikan arahan penting bagi manajemen toko untuk melakukan intervensi berbasis waktu guna menghindari *overstock* dan memaksimalkan efisiensi penyimpanan.

Selanjutnya, dilakukan identifikasi hari-hari dengan permintaan terendah selama 90 hari ke depan berdasarkan output model Prophet. Frekuensi permintaan rendah ditabulasi untuk masing-masing hari dalam sepekan seperti terlihat pada Tabel 11.

Tabel IV-11 Distribusi Frekuensi Prediksi Permintaan Rendah per Hari

Hari	Frekuensi
Senin	5
Selasa	5
Rabu	4
Kamis	3
Jumat	2
Sabtu	4
Minggu	7

Hasil ini menunjukkan bahwa hari Minggu memiliki tingkat permintaan terendah terbanyak, yaitu sebanyak 7 kali, berlawanan dengan asumsi umum tentang puncak aktivitas belanja pada akhir pekan. Oleh karena itu, direkomendasikan program diskon agresif seperti *Flash sale* Minggu Ceria pada hari tersebut, khusus untuk produk *slow-moving*. Senin hingga Rabu dapat dijadikan target diskon ringan untuk menciptakan pemicu pembelian awal pekan (*purchase trigger*), sedangkan Jumat dan Sabtu diposisikan sebagai transisi menuju kampanye promosi akhir pekan.

Tabel IV-12 Rekomendasi Strategi Diskon Mingguan

Hari	Strategi Diskon
Senin	Diskon ringan (5–10%)
Selasa	Bundling promosi
Rabu	<i>Flash deal</i> terbatas waktu
Kamis	Teaser/promosi ringan
Jumat	Pre-campaign awareness
Sabtu	Diskon terbatas kategori
Minggu	Diskon agresif produk <i>slow-moving</i>

Untuk mengevaluasi efektivitas diskon terhadap produk *slow-moving*, dilakukan simulasi diskon pada tiga produk menggunakan skenario potongan 10%, 20%, dan 30%. Estimasi pendapatan dihitung berdasarkan asumsi penjualan sebanyak 20 unit per produk.

Tabel IV-13 Simulasi Diskon Produk *Slow-moving* dan Estimasi Pendapatan

Produk	Diskon	Harga Diskon	Estimasi Pendapatan	Tanggal Diskon
Activity Walker	10%	Rp 292.500	Rp 5.850.000	14 Des
Bando Bandana Bunga	20%	Rp 24.000	Rp 480.000	15 Des
Kursi Makan 6in1	30%	Rp 277.200	Rp 5.544.000	18 Des

Hasil simulasi menunjukkan bahwa strategi diskon moderat (20%) memberikan keseimbangan terbaik antara peningkatan daya tarik produk dan proteksi terhadap margin. Diskon besar (30%) dapat efektif pada produk dengan nilai tinggi yang stagnan, sedangkan diskon kecil (10%) cocok untuk menjaga margin pada produk bernilai tinggi namun memiliki permintaan terukur.

V. KESIMPULAN

Penelitian ini menganalisis tren dan strategi penjualan produk di Toko RumahBayiTAZ dengan memanfaatkan pendekatan *Knowledge Discovery in Databases* (KDD) dan pemodelan *time series* menggunakan algoritma Prophet. Hasil analisis menunjukkan bahwa penjualan historis produk memperlihatkan pola musiman mingguan dan bulanan yang signifikan, ditandai oleh penurunan volume transaksi pada awal minggu dan menjelang pertengahan bulan. Pola tersebut berperan dalam mengidentifikasi produk *slow-moving* secara sistematis berdasarkan frekuensi dan volume penjualan yang konsisten rendah. Pemodelan dengan Prophet menunjukkan performa prediksi yang andal terhadap produk dengan tingkat penjualan rendah, dibuktikan melalui nilai SMAPE yang rendah dan visualisasi prediksi yang akurat serta mudah diinterpretasikan. Model ini juga berhasil menandai hari-hari dengan potensi permintaan rendah yang krusial dalam perumusan strategi penjualan. Strategi diskon berbasis hasil prediksi, seperti "*Flash sale* Minggu Ceria", "*Midweek Deal*", dan promosi pasca-gajian, disusun secara kontekstual terhadap dinamika perilaku konsumen dan waktu rendahnya permintaan. Pendekatan ini terbukti efektif dalam mengoptimalkan penjualan produk *slow-moving* sekaligus meminimalkan risiko penumpukan stok. Secara keseluruhan, penelitian ini menghasilkan model rekomendatif berbasis data untuk mendukung pengambilan keputusan yang adaptif dan strategis dalam pengelolaan inventori serta peningkatan daya saing toko di platform *e-commerce*.

REFERENSI

- [1] A. Ahdiat, "5 E-Commerce dengan Pengunjung Terbanyak di Indonesia (Januari-Desember 2023)," Databoks. Accessed: May 27, 2025. [Online]. Available: <https://databoks.katadata.co.id/teknologi-telekomunikasi/statistik/3c9132bd3836eff/5-e->

commerce-dengan-pengunjung-terbanyak-sepanjang-2023

- [2] C. Chandra and S. Budi, "Analisis Komparatif ARIMA dan Prophet dengan Studi Kasus Dataset Pendaftaran Mahasiswa Baru," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 6, no. 2, Aug. 2020, doi: 10.28932/jutisi.v6i2.2676.
- [3] D. Rizkya, H. Roosaputri, and C. Dewi, "Perbandingan Algoritma ARIMA, Prophet, dan LSTM dalam Prediksi Penjualan Tiket Wisata Taman Hiburan (Studi Kasus: Saloka Theme Park)," *Jurnal Penerapan Sistem Informasi (Komputer & Manajemen)*, vol. 4, no. 3, pp. 507–517, Jul. 2023.
- [4] M. T. Hidayat and M. Sulistiyono, "Analisis Performa Algoritma XGBoost, GRU, dan Prophet dalam Peramalan Penjualan Obat untuk Optimasi Rantai Pasok Farmasi," *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 5, no. 1, pp. 65–73, Jan. 2025, doi: 10.52436/1.jpti.562.
- [5] U. Novita and S. S. E. Putri, "Analisis Pengaruh Promosi dan Diskon dalam Peningkatan Penjualan E-Commerce Era Digital," *Jurnal Pendidikan Tambusai*, vol. 9, no. 1, pp. 11402–11408, 2025.
- [6] M. F. Amalia and D. B. Arianto, "Implementasi Algoritma K-Means Clustering Dalam Klasterisasi Kabupaten/Kota Provinsi Jawa Barat Berdasarkan Faktor Pemicu Stunting Pada Balita," *SIMKOM*, vol. 9, no. 1, pp. 36–46, Jan. 2024, doi: 10.51717/simkom.v9i1.356.
- [7] C. A. Z. Arifin, A. E. Nugraha, and W. Winarno, "Klasifikasi Persediaan pada Gudang Bahan Kemasan XYZ dengan Metode FSN Analysis (Fast, Slow, Non-Moving) Berdasarkan Turn Over Ratio (TOR)," *Go-Integratif: Jurnal Teknik Sistem dan Industri*, vol. 4, no. 02, pp. 76–87, Nov. 2023, doi: 10.35261/gijtsi.v4i02.8906.
- [8] I. P. A. Sanjaya and N. K. Purnawati, "ANALISIS KINERJA MANAJEMEN PERSEDIAAN PRODUK UD. SINAR JAYA KARANGASEM," *E-Jurnal Manajemen Universitas Udayana*, vol. 10, no. 3, p. 270, Mar. 2021, doi: 10.24843/EJMUNUD.2021.v10.i03.p04.
- [9] G. T. S. Gayatri, "Analisis Penerapan Manajemen Pergudangan pada Gudang UMKM Online Shop X," *Co-Value: Jurnal Ekonomi, Koperasi & Kewirausahaan*, vol. 15, no. 4, Oct. 2024, [Online]. Available: <https://journal.ikopin.ac.id>
- [10] A. Alawi and B. Rahardjo, "PENGARUH PROMOSI DAN HARGA TERHADAP KEPUTUSAN PEMBELIAN MELALUI PLATFORM SHOPEE DI SAAT PANDEMI COVID-19," *TRANSEKONOMIKA: AKUNTANSI, BISNIS DAN KEUANGAN*, vol. 2, no. 6, pp. 83–98, Sep. 2022, doi: 10.55047/transekonomika.v2i6.272.
- [11] R. D. Oktaviani and Albari, "Analisis Hubungan antara Online Customers' Shopping Experience, Sikap Loyalitas dan Online Impulsive Buying: Studi pada Pengguna E-Commerce Shopee di Indonesia," *Selekta Manajemen: Jurnal Mahasiswa Bisnis & Manajemen*, vol. 02, no. 05, pp. 133–151, 2023, [Online]. Available: <https://journal.uui.ac.id/selma/index>
- [12] D. B. Mahendra, M. Jefri, B. R. Gumilang, and B. Sutarto, "Analisis Perilaku Konsumen dalam Transaksi Berbasis E-commerce (Studi Kasus Mahasiswa Universitas Pamulang)," *Prosiding Seminar Nasional Manajemen*, vol. 4, no. 1, pp. 143–151, Nov. 2024, [Online]. Available: <http://openjournal.unpam.ac.id/index.php/PSM/index>
- [13] A. W. Sari, I. Djan, M. Wartaka, and Sumardjono, "Analisis Sikap dan Perilaku Konsumen Terhadap Keputusan Pembelian pada Online Marketplace," *Jurnal Ekonomi Efektif*, vol. 5, no. 3, pp. 481–493, Apr. 2023.
- [14] I. G. P. W. Wardhana and I. W. Santiyasa, "Sistem Informasi Prediksi Penjualan E-Commerce Menggunakan Analisis Data Historis dan Algoritma MLR," *Jurnal Nasional Teknologi Informasi dan Aplikasinya*, vol. 1, no. 3, p. 893, Jul. 2023, doi: 10.24843/JNATIA.2023.v01.i03.p15.
- [15] S. Makin, N. Supriana, and M. A. Kurniawan, "Model Peramalan Jumlah Penjualan Sparepart dengan Algoritma Forecasting Time series: Studi Kasus di PT. XYZ," *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 3, no. 6, pp. 265–271, Jul. 2023, doi: 10.52436/1.jpti.306.
- [16] S. J. Taylor and B. Letham, "Forecasting at Scale," *Am Stat*, vol. 72, no. 1, pp. 37–45, Jan. 2018, doi: 10.1080/00031305.2017.1380080.
- [17] I. G. T. Suryawan, I. K. N. Putra, P. M. Meliana, and I. G. I. Sudipa, "Performance Comparison of ARIMA, LSTM, and Prophet Methods in Sales Forecasting," *sinkron*, vol. 8, no. 4, pp. 2410–2421, Oct. 2024, doi: 10.33395/sinkron.v8i4.14057.
- [18] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Comput Sci*, vol. 7, p. e623, Jul. 2021, doi: 10.7717/peerj-cs.623.
- [19] T. Chai and R. R. Draxler, "Root Mean Square Error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature," *Geosci Model Dev*, vol. 7, no. 3, pp. 1247–1250, Jun. 2014, doi: 10.5194/gmd-7-1247-2014.
- [20] U. Fayyad, G. Piatetsky-Shapiro, and P. Smyth, "The KDD process for extracting useful knowledge from volumes of data," *Commun ACM*, vol. 39, no. 11, pp. 27–34, Nov. 1996, doi: 10.1145/240455.240464.
- [21] H. M. Said, "Data Mining and Knowledge Discovery in Big Data for Decision Making in Higher Education," *Biosci Biotechnol Res Commun*, vol. 14, no. 4, pp. 2013–2019, Dec. 2021, doi: 10.21786/bbrc/14.4.93.