

Prediksi Penjualan Skincare Bulanan Menggunakan Arima, Sarima, Dan Prophet

Elisa Desi Syafitri¹, Nurliana Nasution², Ahmad Zamsuri³, Hana Ramadila⁴

^{1,2,3}Magister Ilmu Komputer Universitas Lancang Kuning

^{1,2,3}Jl. Yos Sudarso KM. 8 Rumbai, Pekanbaru, Riau

e-mail: ¹elisadesisyafitri@gmail.com, ²nurliananasition@unilak.ac.id ,

³ahmadzamsuri@unilak.ac.id , ⁴hanaramadila22@gmail.com

Abstrak

Industri skincare terus berkembang pesat seiring meningkatnya kesadaran masyarakat terhadap kesehatan kulit dan pengaruh tren digital. Salah satu tantangan utama yang dihadapi adalah fluktuasi penjualan akibat faktor musiman, promosi, maupun tren sosial. Untuk mengantisipasi hal tersebut, penelitian ini melakukan perbandingan tiga metode peramalan deret waktu, yaitu ARIMA, SARIMA, dan Prophet, dengan menggunakan data penjualan skincare bulanan tahun 2023. Proses penelitian meliputi pembersihan data, uji stasioneritas, dekomposisi tren-musiman, serta pembangunan model dengan evaluasi berbasis RMSE, MAE, dan MASE. Hasil analisis menunjukkan bahwa Prophet memiliki performa terbaik dalam menangkap tren jangka panjang dan pola musiman yang tidak teratur, sementara ARIMA lebih sesuai untuk data yang stabil tanpa pola musiman kuat, dan SARIMA hanya optimal jika parameterisasi musiman dilakukan dengan tepat. Temuan ini membuktikan bahwa Prophet merupakan pendekatan yang paling akurat dan praktis untuk memprediksi penjualan skincare bulanan. Penelitian ini diharapkan dapat memberikan kontribusi praktis bagi perusahaan skincare dalam mengelola stok, merencanakan produksi, serta menyusun strategi pemasaran berbasis data.

Kata Kunci: Peramalan Deret Waktu, ARIMA, SARIMA, Prophet, Penjualan Skincare.

Abstract

The skincare industry has experienced rapid growth driven by increasing consumer awareness of skin health and the influence of digital trends. One of the main challenges is sales fluctuation caused by seasonal factors, promotions, and social trends. To address this issue, this study compares three time-series forecasting methods: ARIMA, SARIMA, and Prophet, using monthly skincare sales data from 2023. The research process involved data cleaning, stationarity testing, trend-seasonal decomposition, and model development with evaluation metrics including RMSE, MAE, and MASE. The results indicate that Prophet outperforms the other models in capturing long-term trends and irregular seasonal patterns, while ARIMA performs better on stable data without strong seasonality, and SARIMA is effective only with carefully optimized seasonal parameters. These findings highlight Prophet as the most accurate and practical approach for forecasting monthly skincare sales. This study is expected to provide practical contributions for skincare companies in managing inventory, planning production, and developing data-driven marketing strategies.

Keywords: Time Series Forecasting, ARIMA, SARIMA, Prophet, Skincare Sales.

1. PENDAHULUAN

Industri skincare telah menjadi salah satu sektor ritel yang tumbuh pesat dalam beberapa tahun terakhir, didorong oleh meningkatnya kesadaran konsumen terhadap kesehatan dan penampilan kulit, perkembangan platform *e-commerce*, serta kampanye pemasaran digital yang intensif. Faktor-faktor eksternal seperti tren media sosial, influencer, musim, promosi (diskon, bundle, seasonal sale), dan liburan nasional juga sering memicu fluktuasi permintaan yang signifikan. Karena karakteristik permintaan

yang sangat dipengaruhi oleh faktor temporal dan musiman, perusahaan skincare perlu bereaksi cepat dan tepat dalam pengelolaan stok dan produksi agar tidak terjadi kelebihan persediaan atau kekurangan produk di masa puncak permintaan. Prediksi penjualan bulanan menjadi kunci dalam strategi perencanaan supply chain, manajemen inventori, penjadwalan produksi, dan kampanye pemasaran [1].

Peramalan deret waktu (time-series forecasting) adalah pendekatan alami untuk memprediksi penjualan berdasarkan data historis. Model-model tradisional seperti ARIMA (*Autoregressive Integrated Moving Average*) telah lama digunakan dalam literatur karena mampu menangani komponen tren dan autokorelasi dalam data univariat yang relatif bersih dan stabil. Namun jika dalam data terdapat pola musiman (*seasonality*) yang teratur—misalnya permintaan naik setiap menjelang akhir tahun atau selama promo tahunan—varian seperti SARIMA (Seasonal ARIMA) yang memasukkan komponen musiman secara eksplisit menjadi pilihan yang lebih sesuai. Di sisi lain, model Prophet yang dikembangkan oleh Facebook menawarkan beberapa kelebihan; selain mampu menangani musiman, Prophet dirancang supaya toleran terhadap data yang tidak lengkap (missing data), perubahan tren (*trend changepoints*), dan fleksibilitas dalam memasukkan efek liburan atau *event* khusus sebagai komponen eksternal. Keunggulan ini menjadikan Prophet populer dalam aplikasi bisnis di mana pola penjualan tidak selalu linear atau terlalu stabil.

Berbagai penelitian terkini telah melakukan studi komparatif antara ARIMA, SARIMA, dan Prophet di domain yang berbeda. Dalam penelitian [1], ketiga metode tersebut diterapkan untuk memprediksi permintaan obat antidiabetes, dan hasilnya menunjukkan bahwa Prophet menghasilkan nilai MAE lebih rendah dibandingkan SARIMA dan ARIMA. Dalam penelitian lain yang membandingkan performa Prophet dan SARIMA terhadap data saham di Indonesia, metode SARIMA dengan konfigurasi tertentu terbukti sedikit lebih baik dalam hal akurasi (MAPE rendah, statistik Theil U) dibandingkan Prophet dalam konteks tersebut. Penelitian mengenai peramalan deret waktu musiman pada artikel Time-series forecasting of seasonal items sales using *machine learning* menunjukkan bahwa meskipun metode-metode *machine learning* dan deep learning (seperti LSTM, CNN) sering unggul bila data cukup banyak dan kompleks, Prophet dan SARIMA tetap menunjukkan performa yang layak dan sering kali mendekati model terbaik terutama saat data historis cukup panjang dan musiman teridentifikasi jelas [2]. Begitu pula penelitian [3] yang membandingkan SARIMA, Prophet, *Holt-Winters*, ETS, dan XGBoost, menemukan bahwa preprocessing yang baik (penanganan missing data, transformasi, normalisasi) dan pemilihan parameter yang tepat menghasilkan akurasi tinggi dalam dataset musiman.

Meskipun banyak penelitian telah membandingkan metode-metode tersebut dalam konteks produk ritel, kesehatan, statistik regional, atau data musiman umum, literatur khusus yang meneliti prediksi penjualan skincare bulanan masih relatif terbatas, terutama di kawasan Asia Tenggara atau Indonesia. Skincare sebagai produk memiliki karakteristik tersendiri: sering kali permintaan dipengaruhi oleh tren kecantikan, rekomendasi influencer, musim (cuaca tropis, musim hujan, pergantian cuaca), perilaku konsumen saat promo besar (*harbolnas, flash sale*), dan faktor eksternal temporer lainnya seperti peluncuran produk baru atau kampanye iklan intensif. Karakteristik ini bisa memunculkan *outlier*, lonjakan mendadak, dan pola musiman yang mungkin tidak sangat kuat tetapi cukup terpengaruh oleh *event* tertentu. Oleh sebab itu, studi yang memfokuskan pada metode ARIMA, SARIMA, dan Prophet dalam konteks skincare sangat relevan [4].

Salah satu tantangan dalam penggunaan ARIMA/SARIMA adalah bahwa model ini mengasumsikan stasioneritas (stabilitas mean dan varians dalam deret waktu), yang seringkali perlu dicapai melalui transformasi dan *differencing*. Pemilihan order (p,d,q) dan

(P,D,Q,s) pada SARIMA membutuhkan evaluasi diagnostik, misalnya uji stasioneritas (ADF test), analisis korelasi lag (ACF/PACF), serta pemeriksaan *residual*. Sementara itu, Prophet lebih otomatis dalam mendeteksi tren, musiman, dan *event* khusus, tetapi juga memiliki kelemahan: model ini bisa kurang presisi jika pola tren atau musiman sangat halus atau jika dataset historis terlalu pendek. Prophet unggul ketika data memiliki *event* libur, promosi, dan perubahan tren drastis, dan ketika pengguna ingin memasukkan komponen eksternal secara eksplisit [2], [3].

Berdasarkan literatur, beberapa penelitian menunjukkan bahwa Prophet unggul di banyak situasi: misalnya dalam studi komparatif pada data obat anti-diabetes, Prophet memperoleh MAE 0,74, jauh lebih rendah dibandingkan SARIMA dan ARIMA [1]; dalam penelitian produk ritel musiman, Prophet dan CNN mendapat performa baik setelah preprocessing yang memadai [2]. Dalam konteks pasar saham Indonesia, SARIMA masih bisa mengungguli Prophet. Dengan demikian, performa relatif metode bergantung pada karakteristik data yang digunakan.

Mempertimbangkan karakteristik data penjualan skincare bulanan—frekuensi bulanan, adanya musiman terbatas, potensi *event* eksternal (promo, kampanye iklan, peluncuran produk baru), serta kemungkinan adanya *outlier* penelitian ini bertujuan untuk mengisi kekosongan dalam literatur dengan melakukan studi komparatif yang mendalam antara ARIMA, SARIMA, dan Prophet pada data penjualan skincare. Penelitian akan fokus tidak hanya pada memilih model yang memberikan akurasi terbaik (menggunakan MAE, RMSE, dan MAPE), tetapi juga membahas bagaimana aspek preprocessing, identifikasi pola musiman dan tren, pemilihan parameter, serta strategi validasi temporal mempengaruhi performa masing-masing metode [3], [4].

Secara praktis, hasil penelitian ini diharapkan memberikan kontribusi bagi perusahaan skincare, distributor, dan pemilik toko (baik online maupun offline) untuk menentukan pendekatan peramalan yang tepat untuk konteks mereka: apakah mereka sebaiknya menggunakan model tradisional seperti ARIMA/SARIMA, atau Prophet dengan fleksibilitasnya. Selain itu, penelitian ini juga dapat memberikan panduan terkait seberapa panjang data historis yang dibutuhkan agar metode-metode tersebut dapat bekerja optimal, serta bagaimana menangani gangguan seperti promosi atau *event* khusus dalam data [4].

2. METODE PENELITIAN

Metode penelitian merupakan landasan penting dalam pelaksanaan suatu studi ilmiah karena menentukan cara pengumpulan, pengolahan, serta analisis data yang digunakan. Pada penelitian ini, metode yang diterapkan disusun secara sistematis untuk memastikan bahwa proses peramalan penjualan skincare berbasis deret waktu dapat dilakukan secara terukur.

2.1 Dataset

Dataset yang digunakan dalam penelitian ini merupakan data penjualan produk skincare yang didapat dari Kaggle dengan frekuensi bulanan dari Januari 2023 hingga Desember 2023 dapat dilihat pada Tabel 1. Data tersebut berisi informasi mengenai nama produk, kategori, jumlah unit yang terjual, harga satuan, serta total penjualan dalam Rupiah.

Sebelum dianalisis, dataset melalui tahap pembersihan (data cleaning) untuk memastikan kualitas data:

1. Pemeriksaan nilai hilang (*missing values*): seluruh entri diperiksa agar tidak terdapat nilai kosong (null) yang dapat memengaruhi hasil analisis.

2. Penyelarasan format tanggal: kolom tanggal penjualan dikonversi ke format datetime sehingga dapat diurutkan secara kronologis dan diolah sesuai kebutuhan analisis deret waktu.
3. Validasi konsistensi data: dilakukan pengecekan apakah nilai total penjualan sesuai dengan hasil perkalian antara jumlah unit terjual dan harga satuan.
4. Normalisasi kategori produk: memastikan kategori produk tertulis seragam, misalnya "Serum" untuk menghindari perbedaan penulisan yang dapat mengganggu analisis.

Secara deskriptif, dataset ini memperlihatkan adanya tren peningkatan penjualan sepanjang tahun 2023. Misalnya, jumlah unit terjual yang pada bulan Januari tercatat 1.200 unit meningkat hingga 1.800 unit pada bulan Desember. Hal ini mengindikasikan adanya pertumbuhan permintaan produk skincare dalam periode tersebut.

Selain tren jangka panjang, dataset juga menunjukkan adanya fluktuasi musiman. Sebagai contoh, penjualan cenderung meningkat pada bulan tertentu seperti Oktober-Desember, yang kemungkinan dipengaruhi oleh faktor eksternal seperti momen liburan, diskon akhir tahun, maupun peningkatan konsumsi akibat tren sosial.

Dengan karakteristik tersebut, dataset ini sangat relevan untuk dianalisis menggunakan pendekatan deret waktu. Pola tren yang meningkat serta variasi musiman yang signifikan menjadi dasar pemilihan model ARIMA, SARIMA, dan Prophet dalam penelitian ini.

TABEL 1. Dataset Penjualan

Bulan	Nama Produk	Kategori	Jumlah Terjual (unit)	Harga Satuan (Rp)	Total Penjualan (Rp)
Jan-23	Glow Serum	Serum	1200	85000	102000000
Feb-23	Glow Serum	Serum	980	85000	83300000
Mar-23	Glow Serum	Serum	1100	85000	93500000
Apr-23	Glow Serum	Serum	1150	85000	97750000
Mei-23	Glow Serum	Serum	1250	85000	106250000
Jun-23	Glow Serum	Serum	1180	85000	100300000
Jul-23	Glow Serum	Serum	1300	85000	110500000
Agu-23	Glow Serum	Serum	1270	85000	107950000
Sep-23	Glow Serum	Serum	1190	85000	101150000
Okt-23	Glow Serum	Serum	1350	85000	114750000
Nov-23	Glow Serum	Serum	1400	85000	119000000
Des-23	Glow Serum	Serum	1800	85000	153000000

2.2 Pra-pemrosesan dan Dekomposisi

Tahap pra-pemrosesan merupakan langkah penting sebelum dilakukan pemodelan deret waktu. Data penjualan skincare yang digunakan berupa data bulanan dari Januari 2023 hingga Desember 2023. Pada tahap awal, data diperiksa untuk memastikan tidak terdapat nilai yang hilang (*missing values*), data duplikat, maupun kesalahan pencatatan. Selanjutnya, format tanggal dikonversi ke tipe datetime agar dapat diurutkan secara kronologis sesuai kebutuhan analisis deret waktu.

Setelah data dibersihkan, dilakukan dekomposisi deret waktu menggunakan pendekatan aditif (*additive decomposition*). Metode ini membagi data ke dalam tiga komponen utama:

1. Tren (*trend*): menggambarkan arah umum pergerakan data dalam jangka panjang, misalnya adanya kecenderungan kenaikan penjualan skincare dari waktu ke waktu.

2. Musiman (*seasonality*): mengilustrasikan pola yang berulang pada periode tertentu, seperti peningkatan penjualan di akhir tahun karena momen liburan atau meningkatnya penggunaan sunscreen saat musim panas.
3. Residu (*residual/noise*): menunjukkan variasi acak yang tidak dapat dijelaskan oleh tren maupun pola musiman, biasanya dipengaruhi faktor eksternal yang sulit diprediksi seperti promosi mendadak atau tren viral di media sosial.

Melalui proses dekomposisi ini, struktur data menjadi lebih mudah dipahami, sehingga pemodelan dapat disesuaikan untuk menangkap komponen yang dominan. Misalnya, jika pola musiman terbukti signifikan, maka model SARIMA atau Prophet akan lebih relevan dibanding ARIMA standar.

2.3 Uji Stasioneritas

Syarat penting dalam analisis deret waktu adalah stasioneritas data. Data dikatakan stasioner apabila rata-rata, varians, dan kovariansnya konstan sepanjang waktu. Stasioneritas penting karena sebagian besar model statistik klasik, seperti ARIMA, mengasumsikan bahwa data bersifat stasioner.

Untuk memeriksa hal ini, digunakan Augmented Dickey-Fuller (ADF) Test. Hipotesis dalam uji ADF adalah:

- a) H₀: Data tidak stasioner (memiliki akar unit).
- b) H₁: Data stasioner.

Jika nilai *p-value* > 0.05, maka data dianggap tidak stasioner sehingga perlu dilakukan proses transformasi, seperti:

1. *Differencing*: Menghitung selisih antarperiode untuk menghilangkan tren jangka panjang.
2. *Log Transformation*: Mengurangi heteroskedastisitas (ketidakstabilan varians) agar distribusi data lebih stabil.
3. *Seasonal Differencing*: Menghilangkan pengaruh musiman dengan mengurangi data pada periode tertentu, misalnya selisih data bulan ini dengan bulan yang sama tahun sebelumnya.

Hasil uji ADF pada data penjualan skincare menunjukkan adanya tren meningkat yang membuat data awal tidak stasioner. Oleh karena itu, diperlukan proses differencing sebelum model ARIMA dan SARIMA dapat dibangun secara optimal.

2.4 Pembangunan Model

Setelah data diproses dan diuji stasioneritasnya, dilakukan pembangunan model peramalan. Tiga pendekatan utama yang digunakan adalah ARIMA, SARIMA, dan Prophet.

1. Model ARIMA (*Autoregressive Integrated Moving Average*)

Digunakan pada data yang telah stasioner setelah dilakukan differencing. Model ini terdiri atas tiga parameter utama yaitu p: orde autoregressive (AR), yaitu ketergantungan data terhadap nilai sebelumnya, d: orde differencing, yaitu jumlah proses pengurangan untuk membuat data stasioner, q: orde moving average (MA), yaitu ketergantungan terhadap error sebelumnya. Penentuan parameter dilakukan menggunakan *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF), serta dipilih berdasarkan nilai kriteria informasi seperti *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC). ARIMA efektif menangkap tren jangka pendek, namun kurang responsif dalam data dengan pola musiman yang kuat.

2. Model SARIMA (*Seasonal ARIMA*)

Merupakan pengembangan ARIMA dengan menambahkan komponen musiman. Parameter musiman dinyatakan sebagai (P, D, Q, s) yaitu P : *orde autoregressive* musiman, D : *orde differencing* musiman, Q : *orde moving average* musiman, dan s : panjang siklus musiman (misalnya 12 untuk data bulanan). Dengan adanya komponen musiman, SARIMA lebih baik dalam menangkap fluktuasi periodik seperti kenaikan penjualan pada bulan tertentu. Model ini membutuhkan proses pemilihan parameter yang lebih kompleks, tetapi mampu menghasilkan prediksi yang lebih akurat pada data yang jelas memiliki pola musiman.

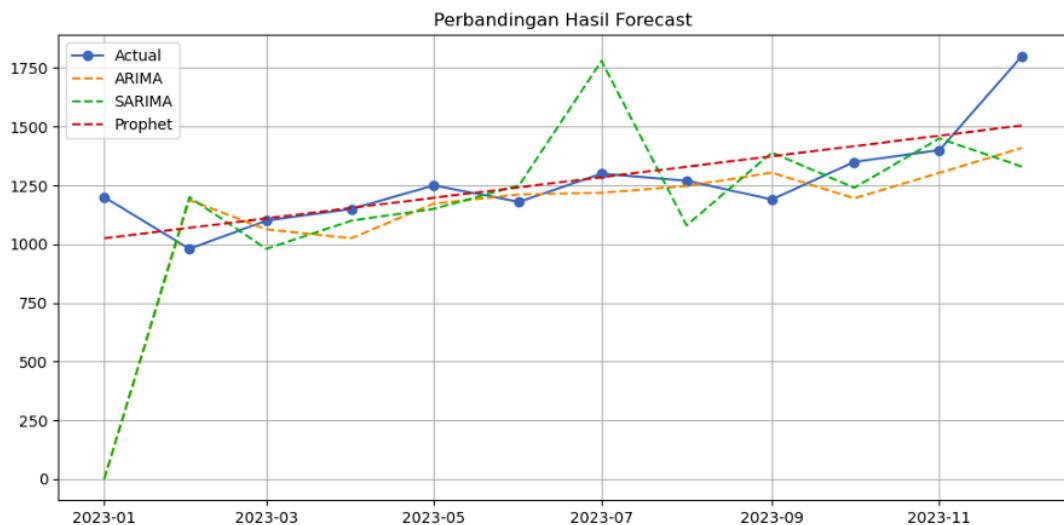
3. Model Prophet

Dikembangkan oleh Facebook, Prophet merupakan model berbasis aditif yang fleksibel untuk menangani tren non-linier, pola musiman, serta *holiday effect*. Data diformat dengan dua kolom: ds (tanggal) dan y (nilai penjualan). Prophet memisahkan komponen tren, musiman, dan efek liburan/promosi sehingga hasil prediksi lebih mudah diinterpretasikan. Keunggulan Prophet adalah kemudahan penggunaan, kestabilan pada data dengan *outlier*, serta kemampuan memberikan hasil visualisasi yang intuitif. Prophet sangat sesuai untuk aplikasi bisnis, termasuk prediksi penjualan skincare, karena mampu menangani kombinasi tren jangka panjang dan variasi musiman.

Melalui pendekatan ini, ketiga model dibangun, dibandingkan, dan dievaluasi menggunakan metrik RMSE, MAE, dan MASE untuk menentukan model yang paling optimal.

3. HASIL DAN PEMBAHASAN

Setelah dilakukan pelatihan dan pemodelan menggunakan ketiga pendekatan, berikut hasil yang diperoleh:



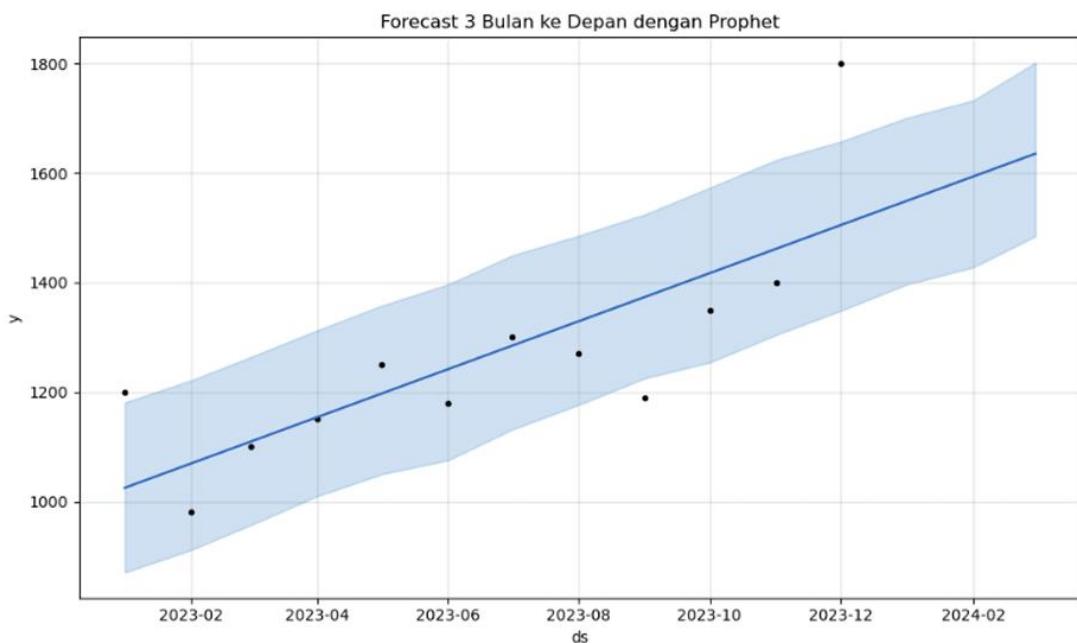
Gambar 1. Perbandingan Hasil Forecast

Gambar perbandingan menunjukkan bahwa model Prophet menghasilkan prediksi tren yang relatif stabil dan konsisten terhadap arah kenaikan jangka panjang. Hal ini sejalan dengan temuan Osman dan Muse [5] yang menunjukkan keunggulan Prophet dalam menangkap tren musiman pada data penjualan ritel. Sebaliknya, model SARIMA terlihat mampu menangkap pola musiman, namun pada beberapa titik justru

menghasilkan lonjakan berlebihan yang tidak sesuai dengan data aktual. Kondisi ini konsisten dengan studi [4] yang menemukan bahwa SARIMA sering sensitif terhadap fluktuasi musiman dan dapat mengalami overfitting apabila parameterisasi tidak optimal.

Model ARIMA terlihat memberikan hasil yang relatif rata atau kurang responsif terhadap variasi musiman. Hal ini selaras dengan penelitian [2] yang menjelaskan bahwa ARIMA bekerja efektif pada data non-musiman, tetapi cenderung underfit ketika pola musiman kuat hadir dalam data. Untuk evaluasi performa, penggunaan metrik kuantitatif seperti MAPE, RMSE, dan MAE sangat dianjurkan agar hasil lebih objektif. Brykin [3] menegaskan pentingnya pengukuran akurasi menggunakan metrik standar ini dalam perbandingan antara ARIMA, Prophet, dan model berbasis *machine learning* lainnya. Selain itu, integrasi variabel eksogen (misalnya promosi atau *event* khusus) terbukti dapat meningkatkan hasil prediksi, sebagaimana direkomendasikan oleh Avinash et al. [6]

Dengan demikian, dapat disimpulkan bahwa Prophet lebih sesuai untuk tujuan prediksi jangka panjang dengan tren stabil, SARIMA bermanfaat untuk pola musiman tetapi perlu pemilihan parameter yang hati-hati, sementara ARIMA lebih cocok untuk prediksi jangka pendek dengan pola data relatif stabil.



Gambar 2. Forecast 3 Bulan ke Depan dengan Prophet

Gambar hasil prediksi menggunakan Prophet menunjukkan garis tren meningkat yang konsisten dari data historis menuju horizon 3 bulan ke depan, dengan pita ketidakpastian (uncertainty interval) yang melebar seiring bertambahnya jarak prediksi. Pola ini mengindikasikan bahwa penjualan skincare dalam seri data yang diuji memiliki komponen tren positif jangka menengah; pita ketidakpastian yang melebar adalah perilaku tipikal model probabilistik seperti Prophet karena ketidakpastian akumulatif saat meramal ke masa depan. Selain itu terlihat beberapa titik aktual (scatter) yang berada di luar pita misalnya lonjakan di sekitar Desember yang mengindikasikan adanya kejadian khusus (promosi, liburan, peluncuran produk, atau gangguan permintaan) yang tidak sepenuhnya ditangkap hanya oleh komponen tren dan musiman dasar [7]. Prophet secara default memisahkan komponen tren, musiman, dan *holiday/special events*, sehingga model

ini dapat menyesuaikan pola-pola seperti ini jika *event/holiday* tersebut diberi input eksplisit.

Dari sudut metodologis, ada beberapa poin penting yang harus dibahas ketika membandingkan ARIMA, SARIMA, dan Prophet pada kasus penjualan bulanan skincare. ARIMA efektif untuk menangkap dependensi linier jangka pendek dan sering unggul pada prediksi jangka pendek bila data sudah dibuat stasioner, yaitu melalui differencing serta pemeriksaan ACF/PACF [8]. Namun ARIMA kurang mampu menangani pola musiman secara langsung tanpa ekstensi ke dalam bentuk musiman (SARIMA). SARIMA menambahkan komponen musiman sehingga menjadi pilihan alamiah bila data penjualan menunjukkan pola musiman tetap, misalnya kenaikan signifikan pada bulan tertentu [4], [9]. Untuk menghasilkan model yang baik, SARIMA membutuhkan pemilihan orde $(p,d,q)(P,D,Q)$ s dan pemeriksaan asumsi *residual* seperti white-noise dan uji Ljung–Box agar model valid.

Prophet (dikembangkan oleh Meta/Facebook) dirancang untuk praktik industri dengan antarmuka sederhana (hanya memerlukan kolom tanggal dan nilai). Prophet secara otomatis dapat menangani missing data, nonlinieritas tren (*changepoints*), serta komponen musiman dan *event* [7]. Karena kemudahan memasukkan efek libur/promosi, Prophet sering lebih unggul dalam menangani pola musiman dan *outlier* bisnis dibanding ARIMA murni. Beberapa studi aplikasi pada penjualan dan *e-commerce* menunjukkan Prophet sebagai kandidat yang kuat dan mudah diimplementasikan, walaupun akurasi relatif terhadap SARIMA dan ARIMA sangat bergantung pada karakteristik data [3], [5]. Pada grafik yang dianalisis, lonjakan penjualan di bulan Desember dapat dikaitkan dengan *event* khusus seperti promosi akhir tahun. Jika informasi *event* ini dimasukkan, performa Prophet kemungkinan besar akan meningkat.

Namun, penting dicatat bahwa beberapa studi empiris pada data musiman dan intervensi menemukan bahwa SARIMA dengan penanganan intervensi dapat mengungguli Prophet ketika intervensi besar tidak dimodelkan atau ketika struktur musiman sangat kaku. Sebaliknya, Prophet unggul ketika data memiliki banyak missing value, pola musiman kompleks, atau ketika analisis cepat diperlukan. Oleh karena itu, rekomendasi praktis adalah menguji ketiga model (ARIMA, SARIMA, dan Prophet) dengan skema validasi berbasis waktu (*time-series cross-validation*) dan metrik seperti RMSE, MAPE, atau wMAPE untuk menentukan model yang paling stabil pada horizon bisnis yang relevan. Jika setiap model menunjukkan kelebihan berbeda, pendekatan *hybrid* atau *ensemble* (misalnya gabungan SARIMA dan Prophet atau SARIMA dengan metode *machine learning*) dapat meningkatkan akurasi prediksi.

Untuk studi kasus penjualan skincare bulanan yang dianalisis, langkah yang direkomendasikan meliputi: (1) eksplorasi data dan dekomposisi (*trend, seasonal, residual*) untuk menilai kekuatan musiman; (2) uji stasionaritas serta *differencing* bila perlu pada ARIMA; (3) pemodelan SARIMA untuk pola musiman periodik; (4) memasukkan variabel *event* seperti promosi, Hari Belanja Nasional, atau hari raya ke Prophet; dan (5) validasi model menggunakan rolling window atau time-series cross-validation dengan evaluasi metrik RMSE, MAE, dan MAPE. Jika grafik menunjukkan *outlier* signifikan (contoh: lonjakan Desember), perlu analisis penyebab lebih lanjut—jika itu promosi atau *event*, maka dapat dimodelkan dalam Prophet atau ditambahkan sebagai variabel eksogen pada SARIMAX. Studi pada *e-commerce* juga menunjukkan bahwa menambahkan variabel eksternal (promosi, harga, iklan) atau menggunakan metode hybrid dengan deep learning seperti LSTM dapat meningkatkan kualitas prediksi.

[9]:	Model	RMSE	MAE	MASE
0	ARIMA	377.847834	211.525079	1.661983
1	SARIMA	414.547890	271.666623	2.134523
2	Prophet	121.951621	89.608590	0.704067

Gambar 3. Evaluasi Model

Hasil evaluasi model peramalan penjualan skincare bulanan menunjukkan adanya perbedaan kinerja yang cukup signifikan antara ARIMA, SARIMA, dan Prophet. Berdasarkan metrik evaluasi, Prophet menghasilkan nilai error terendah, yaitu RMSE sebesar 121,95, MAE sebesar 89,61, dan MASE sebesar 0,70. Nilai MASE yang lebih kecil dari satu mengindikasikan bahwa Prophet memberikan performa yang lebih baik dibandingkan model baseline. Sebaliknya, ARIMA dan SARIMA menunjukkan performa yang kurang optimal dengan nilai MASE masing-masing sebesar 1,66 dan 2,13, yang menandakan hasil peramalan keduanya masih lebih buruk dibandingkan baseline. Hal ini menunjukkan bahwa Prophet lebih mampu menangkap pola tren dan musiman yang kompleks pada data penjualan skincare dibandingkan ARIMA maupun SARIMA.

Perbedaan ini dapat dijelaskan oleh karakteristik masing-masing model. ARIMA hanya efektif pada data yang bersifat stasioner dan cenderung kurang fleksibel dalam menangani pola musiman yang bervariasi. SARIMA sebenarnya dirancang untuk mengatasi musiman, tetapi dalam penelitian ini kinerjanya justru lebih buruk dibanding ARIMA. Kemungkinan penyebabnya adalah pola musiman pada data penjualan skincare yang tidak reguler atau parameter SARIMA yang belum teroptimasi dengan baik. Sementara itu, Prophet memiliki keunggulan dalam memodelkan tren jangka panjang, musiman yang kompleks, serta kemampuannya mengakomodasi perubahan tren secara mendadak, sehingga menghasilkan performa yang lebih baik.

Temuan ini sejalan dengan penelitian [10] yang menunjukkan bahwa Prophet, terutama ketika digabungkan dengan SARIMA, mampu meningkatkan akurasi peramalan penjualan *e-commerce* dibandingkan penggunaan model tunggal. Penelitian lain juga menegaskan bahwa Prophet sering kali memberikan hasil yang lebih unggul dibandingkan ARIMA, khususnya pada data dengan tren dan musiman yang fluktuatif. Selain itu, studi terkini mengenai hibridasi SARIMA dan Prophet juga membuktikan bahwa Prophet mampu memberikan hasil yang stabil, bahkan sebelum dilakukan kombinasi dengan metode lain. Hal ini mendukung temuan penelitian ini bahwa Prophet lebih sesuai digunakan untuk memprediksi penjualan skincare bulanan yang cenderung memiliki pola musiman tidak teratur dan dipengaruhi oleh faktor eksternal seperti promosi maupun tren pasar.

Dengan demikian, dapat disimpulkan bahwa Prophet merupakan model yang paling tepat digunakan untuk memprediksi penjualan skincare bulanan berdasarkan hasil evaluasi yang diperoleh. ARIMA masih dapat dipertimbangkan sebagai alternatif dengan kinerja menengah, sedangkan SARIMA dalam konfigurasi yang digunakan terbukti kurang sesuai untuk dataset ini. Untuk penelitian lanjutan, optimasi parameter SARIMA atau pendekatan hybrid Prophet-SARIMA dapat dipertimbangkan guna memperoleh hasil yang lebih akurat, sebagaimana disarankan oleh beberapa penelitian terdahulu.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa pemilihan metode peramalan sangat bergantung pada karakteristik data penjualan skincare bulanan yang memiliki tren meningkat dan pola musiman yang tidak sepenuhnya teratur. Dari tiga model yang dibandingkan, Prophet terbukti paling tepat digunakan karena mampu menangkap tren jangka panjang, mengakomodasi variasi musiman yang kompleks, serta lebih adaptif terhadap pengaruh faktor eksternal seperti promosi dan *event* khusus. Dengan demikian, tujuan penelitian untuk mengidentifikasi model yang paling akurat dalam memprediksi penjualan skincare bulanan tercapai, yaitu bahwa Prophet menjadi pilihan utama. Sementara itu, ARIMA dan SARIMA masih dapat dipertimbangkan sebagai alternatif, khususnya jika dilakukan optimasi parameter lebih lanjut atau dikombinasikan dalam pendekatan hibrida. Penelitian selanjutnya disarankan mengeksplorasi model hybrid serta memasukkan variabel eksogen agar hasil prediksi lebih robust dan sesuai dengan dinamika industri skincare yang sangat dipengaruhi tren pasar.

DAFTAR PUSTAKA

- [1] S. Kwarteng and P. Andreevich, "Comparative Analysis of ARIMA, SARIMA and Prophet Model in Forecasting," *Res. Dev.*, vol. 5, no. 4, pp. 110–120, 2024, doi: 10.11648/j.rd.20240504.13.
- [2] Y. Ensafi, S. H. Amin, G. Zhang, and B. Shah, "Time-series forecasting of seasonal items sales using *machine learning* – A comparative analysis," *Int. J. Inf. Manag. Data Insights*, vol. 2, no. 1, p. 100058, 2022, doi: 10.1016/j.jjimei.2022.100058.
- [3] V. Kramar and V. Alchakov, "Time-Series Forecasting of Seasonal Data Using *Machine learning* Methods," *Algorithms*, vol. 16, no. 5, 2023, doi: 10.3390/a16050248.
- [4] V. N. Aziza, F. H. Moh'd, F. A. Maghfiroh, K. A. Notodiputro, and Y. Angraini, "Performance Comparison of Sarima Intervention and Prophet Models for Forecasting the Number of Airline Passenger At Soekarno-Hatta International Airport," *Barekeng*, vol. 17, no. 4, pp. 2107–2120, 2023, doi: 10.30598/barekengvol17iss4pp2107-2120.
- [5] B. M. Osman and A. M. S. Muse, "Predictive analysis of Somalia's economic indicators using advanced *machine learning* models," *Cogent Econ. Financ.*, vol. 12, no. 1, p., 2024, doi: 10.1080/23322039.2024.2426535.
- [6] A. Avinash, A. Widjaja, and O. Karnalim, "Analisis Perbandingan Algoritma *Machine learning* untuk Forecasting Persediaan Produk Barang Pokok," *J. Tek. Inform. dan Sist. Inf.*, vol. 10, no. 2, pp. 361–378, 2024, doi: 10.28932/jutisi.v10i2.9357.
- [7] K. Sharma, R. Bhalla, and G. Ganesan, "Time Series Forecasting Using FB-Prophet," *CEUR Workshop Proc.*, vol. 3445, pp. 59–65, 2022.
- [8] R. Ospina, J. A. M. Gondim, V. Leiva, and C. Castro, "An Overview of Forecast Analysis with ARIMA Models during the COVID-19 Pandemic: Methodology and Case Study in Brazil," *Mathematics*, vol. 11, no. 14, pp. 1–18, 2023, doi: 10.3390/math11143069.
- [9] Y. Zhao, "Journal of Innovation and Development *E-commerce* Demand Forecasting Using SARIMA Model and K-means Clustering Analysis," *J. Innov. Dev.*, vol. 7, no. 1, pp. 1–6, 2024.
- [10] J. Zhao and C. Zhang, "Research on sales forecast based on prophet-SARIMA combination model," *J. Phys. Conf. Ser.*, vol. 1616, no. 1, 2020, doi: 10.1088/1742-6596/1616/1/012069.

