

Analisis Time Series dan Perancangan Dashboard untuk Memprediksi Penjualan dengan Metode Prophet dan SARIMAX

Brian Khaw¹, Ricky Irwanto², Roni Yunis³, Elly⁴

^{1,2,3,4}Universitas Mikroskil, Jl. M.H Thamrin No.140, 0614573767

^{1,2,3,4}Fakultas Informatika, Sistem Informasi, Universitas Mikroskil, Medan

e-mail: ¹briankhaw125@gmail.com, ²irwantoricky0@gmail.com, ³roni@mikroskil.ac.id,
⁴elly@mikroskil.ac.id

Dikirim: 14-07-2025 | Diterima: 07-08-2025 | Diterbitkan: 31-10-2025

Abstrak

Penelitian ini membahas analisis data deret waktu untuk memprediksi penjualan menggunakan metode Prophet dan SARIMAX. Metode ini dipilih karena mampu menangani pola musiman, tren, dan faktor eksternal yang penting dalam memaksimalkan akurasi prediksi penjualan. Dataset Walmart dari periode 2012-2015 digunakan sebagai data utama, sementara data eksternal diambil dari Google Trends. Penelitian ini menggunakan kerangka kerja OSEMN yang meliputi pengumpulan, pembersihan, eksplorasi, pemodelan, dan interpretasi data. Hasil evaluasi menunjukkan model SARIMAX lebih unggul pada skenario mingguan dan bulanan dengan MAPE sebesar 2,589% dan 0,930% dibandingkan model Prophet dengan MAPE sebesar 2,753% dan 1,045%. Hasil penelitian ini juga menunjukkan penambahan faktor eksogen pada kedua model ini tidak memberikan dampak yang signifikan dalam meningkatkan performa model. Hasil prediksi data penjualan divisualisasi melalui dashboard interaktif yang membantu pengguna memahami hasil prediksi secara intuitif.

Kata kunci: deret waktu, Prophet, SARIMAX, peramalan penjualan, dasbor.

Abstract

This research paper sets out the analysis of time series data for the purpose of sales prediction, with a particular focus on the utilisation of the Prophet and SARIMAX methods. The selection of these methods was made on the basis of their ability to manage seasonal patterns, trends, and external factors that are deemed to be of significance in optimising the accuracy of sales prediction. The primary data set for this study was sourced from the Walmart dataset spanning the years 2012 to 2015, with additional data obtained from Google Trends. The OSEMN framework was employed, encompassing data collection, cleansing, exploration, modelling, and interpretation. The evaluation results indicate that the SARIMAX model outperforms the Prophet model in weekly and monthly scenarios, with MAPE values of 2.589% and 0.930%, respectively, as compared to the Prophet model's MAPE values of 2.753% and 1.045%. The results also demonstrate that the incorporation of exogenous factors in these two models does not result in a substantial enhancement of model performance. The prediction results for sales data are presented through an interactive dashboard, which assists users in comprehending the prediction outcomes intuitively.

Keywords: time series, Prophet, SARIMAX, sales forecasting, dashboard.

1. PENDAHULUAN

Di era perkembangan teknologi yang pesat, jumlah data yang dihasilkan semakin banyak dan beragam. Data merupakan komoditas paling berharga bagi organisasi di abad ke-21 [1], terutama dalam peramalan penjualan yang memiliki peran penting untuk manajemen inventaris, analisis penawaran dan permintaan, strategi bisnis dan pengambilan keputusan bisnis [2]. Dengan peramalan penjualan yang akurat, sebuah organisasi dapat membuat keputusan bisnis yang tepat. Sebagai contoh, peramalan penjualan yang akurat dapat digunakan untuk manajemen inventaris untuk memenuhi kebutuhan pelanggannya [3]. Namun, terdapat tantangan seperti pola musiman yang kompleks, tren yang tidak stabil, dan kejadian khusus (*event-driven*), serta faktor eksternal seperti jumlah pencarian di *website* dapat mempengaruhi akurasi peramalan penjualan. Salah satu metode peramalan yang dapat digunakan untuk menangani hal ini adalah metode analisis *time series*. Metode ini juga memungkinkan untuk mengidentifikasi pola, musiman, ketidakteraturan, pengulangan menggunakan data historis berdasarkan urutan waktu dan faktor eksternal [4], [5].

Pada penelitian ini, metode analisis *time series* yang digunakan adalah Prophet dan SARIMAX. Alasan menggunakan kedua metode ini adalah karena mampu menangani pola musiman dan faktor eksternal. Prophet merujuk pada 3 elemen utama dalam melakukan peramalan *time series* yaitu tren, pola musiman, dan hari libur [6]. Prophet juga dapat menangani faktor eksternal dengan menambahkan regresi tambahan agar dapat mengolah lebih banyak data yang relevan untuk meningkatkan akurasi peramalan penjualan. Prophet juga dapat menangani *missing value* dan nilai yang tidak wajar (*outlier*) dengan baik [7]. Metode SARIMAX (*Seasonal Autoregressive Integrated and Moving Average with Exogenous Variable*) adalah gabungan dari metode SARIMA dan faktor X yang mewakili nilai eksogen. Metode SARIMA merupakan perkembangan dari metode ARIMA yang dirancang untuk menangani komponen musiman atau siklus dalam data *time series* karena metode ARIMA memiliki keterbatasan dalam menangani komponen tersebut [8]. SARIMA hanya mengacu pada konfigurasi parameter *autoregressive* (AR), *moving average* (MA), *differencing* (I), serta komponen musiman (P, D, Q), sedangkan SARIMAX memiliki tambahan faktor eksternal yaitu X untuk mengoptimalkan hasil peramalan dengan menambahkan faktor eksternal yang mempengaruhi keakuratan peramalan [9].

Setelah melakukan peramalan penjualan, hasil analisis perlu divisualisasikan dalam sebuah dashboard yang informatif dan interaktif. *Dashboard* yang informatif adalah *dashboard* yang menampilkan metrik penting dari penjualan. Sementara itu, *dashboard* yang interaktif memungkinkan pengguna untuk berinteraksi dengan data secara dinamis seperti fitur filter, drill down, dan grafik yang dinamis. Sehingga *dashboard* ini dapat digunakan oleh manajemen untuk mempercepat pengambilan keputusan bisnis, melacak kinerja, dan meningkatkan produktivitas [10].

Dengan demikian, penelitian ini bertujuan untuk menunjukkan bagaimana memanfaatkan data yang sangat banyak dan berharga dalam peramalan penjualan dengan menggunakan salah satu faktor eksternal yaitu jumlah pencarian di *website*, dan memvisualisasikan data tersebut ke dalam sebuah *dashboard*, serta mengisi kesenjangan (*gap*) penelitian terdahulu yang hanya berfokus pada pola historis penjualan seperti tren dan pola musiman.

2. TINJAUAN PUSTAKA

2.1 Peramalan Penjualan

Peramalan penjualan adalah proses menggunakan data dan informasi saat ini untuk memperkirakan atau memprediksi jumlah produk atau jasa yang akan terjual dalam periode tertentu di masa depan. Peramalan penjualan membantu organisasi membuat keputusan yang lebih baik dengan memberi tahu tentang pola dan tren yang mungkin terjadi di masa depan, sehingga memungkinkan organisasi membuat keputusan yang lebih baik [11].

Dalam implementasi peramalan penjualan, terdapat beberapa penelitian terdahulu yang menunjukkan bagaimana peramalan dapat membantu bisnis dalam pengambilan keputusan dan operasional. Contohnya penelitian tentang peramalan penjualan alkohol di Amerika Serikat yang

menggunakan metode Prophet untuk menangani data time series dengan mempertimbangkan faktor musiman dan hari libur, menghasilkan peramalan penjualan yang memungkinkan perusahaan untuk perencanaan dan pengelolaan stok alkohol berdasarkan hasil peramalan [6]. Selain itu, penelitian tentang peramalan penjualan pada BigMart menerapkan beberapa model machine learning sebagai pengembangan model prediktif, dengan tujuan untuk meningkatkan hasil peramalan penjualan yang sangat penting dalam keberlangsungan bisnis [12]. Dengan demikian, perusahaan dapat merencanakan strategi yang lebih efektif dan mengalokasikan anggaran yang lebih efisien.

2.2 Time Series

Time series mengacu pada sekumpulan data atau informasi yang dikumpulkan dalam interval waktu tertentu, seperti harian, mingguan, bulanan, atau tahunan. Data *time series* digunakan untuk mengidentifikasi pola atau tren yang mungkin terdapat dalam data tersebut. Contohnya data historis penjualan suatu perusahaan dapat digunakan untuk meramal penjualan di masa depan dengan mengidentifikasi pola atau tren dari data tersebut. Dengan memanfaatkan data time series, organisasi dapat membuat keputusan yang tepat, merencanakan strategi yang lebih efektif, dan mengantisipasi perubahan yang mungkin terjadi di masa depan [13].

2.3 Analisis Time Series

Analisis *time series* adalah metode khusus untuk menganalisis rangkaian titik data yang dikumpulkan selama periode waktu tertentu. Dalam analisis time series, analisis ini mencatat titik data pada interval yang konsisten selama periode waktu tertentu, bukan hanya mencatat titik data secara acak atau secara terputus-putus. Waktu menjadi variabel penting karena menunjukkan bagaimana data berubah sepanjang titik data dan hasil akhirnya [14].

Analisis *time series* digunakan untuk menganalisis data non-stasioner. Data non-stasioner adalah data yang terus berfluktuasi sepanjang waktu atau dipengaruhi oleh waktu. Sebagai contoh industri seperti keuangan, ritel, dan ekonomi sering menggunakan analisis deret waktu karena mata uang dan penjualan selalu berubah. Analisis *time series* membantu organisasi memahami penyebab utama dari pola atau tren sistemik yang berubah dari waktu ke waktu. Organisasi dapat melihat pola-pola yang teridentifikasi di masa depan dengan *Forecasting time series* dan mempelajari lebih lanjut mengapa pola tersebut terjadi dengan menggunakan tools visualisasi data. *Forecasting time series* merupakan bagian dari analisis prediktif yang dapat menunjukkan kemungkinan perubahan dalam data di masa depan yang disebabkan oleh beberapa faktor, seperti perilaku musiman. Hal ini memungkinkan organisasi membuat peramalan rangkaian waktu untuk memprediksi kemungkinan kejadian di masa depan. Ini memberikan pemahaman yang lebih baik tentang variabel data dan membantu peramalan yang dilakukan organisasi menjadi dengan lebih baik [15].

Dalam analisis *time series*, terdapat komponen-komponen yang dapat diidentifikasi. Berikut adalah komponen yang terdapat dalam analisis *time series* [16]:

1. *Trend*: menggambarkan kecenderungan jangka panjang dari data yang menunjukkan perubahan dari satu periode ke periode berikutnya. Tren dapat dibagi menjadi dua, yaitu *zero-basis trend* dan level dalam data. *Level* dalam *time series* tetap konstan seiring waktu, sementara *zero-basis trend* mengalami perubahan.
2. *Seasonal*: mengacu pada pola berulang yang terjadi selama siklus waktu tertentu. Musiman dapat dibagi menjadi musiman per jam, harian, mingguan, atau tahunan.
3. *Cycle*: menggambarkan pola fluktuasi jangka panjang yang tidak memiliki interval waktu tetap. Siklus sering dipengaruhi oleh faktor ekonomi atau faktor eksternal lainnya. Contohnya adalah siklus ekonomi yang mencakup fase *boom* dan resesi. Fase ini menunjukkan pola berulang, namun jangka waktu setiap fase dan penggantinya tidak terjadi secara pasti dan bersifat acak.
4. *Irregular/Noise*: mencakup variasi acak yang tidak dapat diprediksi dalam data. Ini mencerminkan fluktuasi acak yang tidak mengikuti pola tertentu, tetapi dapat berdistribusi normal dalam kasus ideal. Pada setiap data *time series* pasti memiliki komponen ini.

2.4 Prophet

Prophet adalah algoritma peramalan data yang berbentuk deret waktu. Prophet berdasar pada model aditif untuk menyesuaikan tren non-linier dengan tren tahunan, mingguan, dan harian musiman, ditambah efek liburan. Prophet juga dirancang untuk memungkinkan penyesuaian parameter tanpa mengetahui seluruh model yang mendasarinya [17].

Prophet memiliki lima parameter utama yaitu *model type*, *changepoints*, *seasonality*, *holidays*, dan *error* [18]. Berikut persamaan dasar model Prophet [6]:

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (1)$$

Keterangan:

$g(t)$ = fungsi tren yang mengimplementasikan perubahan non-periodik dalam *time series*.

$s(t)$ = fungsi yang berisi variasi musiman (seperti tahunan, bulanan, dan mingguan).

$h(t)$ = fungsi yang mewakili efek liburan.

ϵ_t = fungsi yang mewakili kesalahan yang terkait dengan variasi yang tidak disertakan oleh model.

Faktor $g(t)$ bisa dimodelkan dalam dua model yaitu [19]:

1. *Logistic Growth Model*: model ini mewakili pertumbuhan dalam berbagai tahap pada tahap pertama pertumbuhan diamati kira-kira eksponensial setelah tahap saturasi itu mencapai dari sana ia tumbuh secara linear. Berikut persamaan modelnya:

$$f(x) = \frac{L}{1 + e^{-k(x-x_0)}} \quad (2)$$

Keterangan:

L : mewakili nilai maksimum dari model kurva.

k : tingkat pertumbuhan.

x_0 : nilai x di titik sigmoid

2. *Piecewise Linear Model*: merupakan versi modifikasi dari model linier di mana rentang x yang berbeda memiliki perbedaan hubungan linier. Berikut persamaan modelnya:

$$y = \beta_0 + \beta_1 x + \beta_2 (x - c)^+ + \epsilon \quad (3)$$

Pengaruh fluktuasi musiman harian, mingguan, dan tahunan secara periodik pada dataset didefinisikan oleh persamaan berikut [20], [21]:

$$S(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right) \quad (4)$$

Keterangan:

P : periode waktu

Dampak dari hari libur (holiday) dapat didefinisikan dengan persamaan berikut [20], [21]:

$$h(t) = [1(t \in D1), \dots, 1(t \in DL)]k \quad (5)$$

Keterangan:

D = set dari tanggal libur masa lalu dan masa depan

t = waktu saat sedang libur

k = perubahan hari libur saat prediksi

Berikut adalah penjelasan kelima parameter utama dalam model Prophet yang dapat dilihat pada Tabel 1.

Tabel 1. Parameter Model Prophet

Parameter	Penjelasan
<i>Model type</i>	Parameter ini dapat diklasifikasikan sebagai model <i>linear</i> atau <i>logistic</i> . Dalam model <i>linear</i> , <i>outlier</i> dinormalisasi dan tidak ada batas maksimum atau minimum yang ditetapkan. Model <i>logistic</i> digunakan untuk prakiraan jenuh, di mana nilai tertinggi dan terendah ditentukan. Parameter ini dimasukkan ke dalam model dengan fungsi <i>growth</i> [18].
<i>Seasonality</i>	Parameter ini menggambarkan pola musiman pada data <i>time series</i> yang berulang dalam interval harian, mingguan, dan tahunan [18].
<i>Holidays</i>	Parameter ini dapat memberikan dampak signifikan terhadap peramalan pada data <i>time series</i> , dan sering kali tidak mengikuti pola periodik, sehingga tidak dapat dimodelkan dengan baik. <i>Holidays</i> dan <i>event</i> spesial pada <i>time series</i> biasanya serupa dari tahun ke tahun, sehingga penting untuk digunakan dalam peramalan [22].
<i>Changepoints</i>	Parameter ini mendeteksi jumlah <i>changepoints</i> dan akan memungkinkan tren untuk beradaptasi dengan tepat. Meskipun memiliki fungsi otomatis, jumlah <i>changepoints</i> dapat ditentukan atau dikontrol. Untuk menentukan <i>changepoints</i> , Prophet mendeteksi <i>changepoints</i> dengan menentukan sejumlah besar <i>changepoints</i> potensial dengan tingkat perubahan diperbolehkan untuk berubah, dan kemudian menggunakan regularisasi L1 untuk memilih beberapa titik yang akan digunakan dalam model [17], [18].
<i>Cross validation</i>	Parameter ini berfungsi untuk mengukur <i>error</i> peramalan yang menggunakan data historis. Fungsi ini dilakukan dengan menentukan titik <i>cutoff</i> dalam data historis, di mana model hanya akan dilatih menggunakan data hingga titik <i>cutoff</i> . Kemudian hasil peramalan dapat dibandingkan dengan nilai aktual [23].

Selain kelima parameter utama tersebut, terdapat parameter lain yang bernama additional regressor. Parameter ini berfungsi sebagai parameter untuk faktor eksternal dalam peramalan. Additional regressor dapat dimasukkan ke dalam model dengan fungsi `add_regressor`. Additional regressor berupa variabel yang mungkin mempengaruhi peramalan dan data pada variabel berupa time series [22].

2.5 SARIMAX

Model SARIMAX (*Seasonal Autoregressive Integrated and Moving Average with Exogenous Variable*) merupakan pengembangan dari ARIMA model, yang pertama kali diperkenalkan oleh Box dan Jenkins pada tahun 1976. Model ini merupakan model peramalan deret waktu yang akurat dengan menggunakan berbagai elemen untuk mengidentifikasi dan memprediksi pola temporal yang kompleks dalam data [24]. SARIMAX juga merupakan model SARIMA dengan tambahan variabel luar sehingga disebut SARIMAX (p, d, q) (P, D, Q)s (X), dimana X adalah variabel luar. Variabel luar dapat dimodelkan dengan persamaan regresi linier multi dinyatakan sebagai berikut [25]:

$$Y_t = \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_k X_{k,t} + \epsilon_t \quad (6)$$

Berikut penjelasan elemen pada model SARIMAX [24], [26]:

1. S (*Seasonal*): SARIMAX menggabungkan efek musiman, yang diwakili dengan huruf 'S'. Komponen ini dapat mengetahui adanya pola musiman dalam data deret waktu, yang umum banyak terjadi, terutama ketika berkaitan dengan perilaku manusia. Seperti permintaan mantel musim dingin yang meningkat selama bulan-bulan yang lebih dingin menurun di musim panas. Pola musiman biasanya terjadi seminggu atau sebulan, tetapi juga dapat muncul pada interval

waktu yang berbeda. Parameter ini disimbolkan sebagai “s”. Berikut persamaan komponen *seasonal* dibangun:

$$\left(\sum_{j=1}^P \phi_j \Delta_s y_{t-j_s}\right) - \left(\sum_{j=1}^Q \theta_j \epsilon_{t-j_s}\right) + \epsilon_t \quad (7)$$

2. AR (*Autoregressive*): Komponen ini menggabungkan nilai-nilai masa lalu secara linear, yang dikenal sebagai "*p-lags*", seperti yang ditunjukkan pada persamaan yang ditunjukkan dibawah. Dengan kata lain, SARIMAX mengkaji sejarah nilai deret waktu dan menggunakan kombinasi dari observasi masa lalu untuk memprediksi nilai $\hat{y}_t$. Ini adalah bobot yang diberikan pada lag, yang sesuai dengan nilai α . Parameter AR disimbolkan sebagai “p”. Berikut persamaan komponen ini:

$$\hat{y}_t = \alpha t - p y_{t-p} + \alpha_{t-p+1} y_{t-p+1} + \dots + \alpha_{t-1} y_{t-1} \quad (8)$$

3. I (*Integration*): Huruf 'I' pada SARIMAX merupakan singkatan untuk integrasi. Komponen ini berfungsi untuk mengatasi asumsi stasioner. SARIMAX menggunakan pengintegrasian atau pembedaan dalam model untuk membuat data non stasioner menjadi stasioner. Parameter ini disimbolkan sebagai “d” Berikut persamaannya dengan diwakili dengan segitiga atau delta (Δ):

$$\Delta Y_t = c + \left(\sum_{i=1}^p \alpha_i \Delta y_{t-i}\right) - \left(\sum_{i=1}^q \theta_i \epsilon_{t-i}\right) + \epsilon_t \quad (9)$$

4. MA (*Moving Average*): ‘MA’ dalam SARIMAX berarti rata-rata pergerakan. Komponen ini menunjukkan bahwa ramalan SARIMAX tidak hanya berdasarkan pola data di masa lalu, tetapi juga mempertimbangkan kesalahan yang dibuat dalam ramalan sebelumnya. Namun, kesalahan ramalan ini hanya dapat diketahui setelah model dipasang, sehingga sulit untuk menghitung jumlah kesalahan masa lalu (dikenal sebagai "*q-lags*") yang ideal untuk dipertimbangkan. MA disimbolkan sebagai “q” Berikut adalah persamaannya:

$$\hat{y}_t = c + \theta t - q \epsilon_{t-q} + \theta_{t-q+1} \epsilon_{t-q+1} + \dots + \theta_{t-1} \epsilon_{t-1} \quad (10)$$

kesalahan ϵ dihitung seperti persamaan berikut:

$$\epsilon_t = y_t - \hat{y}_t \quad (11)$$

5. X (*Exogenous Variables*): 'X' pada SARIMAX menunjukkan bahwa model memiliki kemampuan untuk mempertimbangkan variabel eksogen saat membuat peramalan. Variabel eksogen adalah faktor eksternal yang dapat mempengaruhi analisis time series. SARIMAX memasukkan istilah tambahan βX ke dalam model dasar ARIMA untuk mengakomodasi variabel-variabel ini. Ini memungkinkan informasi eksogen dimasukkan ke dalam proses peramalan. Oleh karena itu, X diintegrasikan dengan memperkirakan dampak atau koefisiennya terhadap model sementara yang tepat. Biasanya, estimasi maksimum atau estimasi kuadrat terkecil digunakan untuk melakukan ini. Koefisien tersebut dianggap sebagai konstanta dan tidak bergantung pada t . Model yang lengkap menyediakan komponen musiman dan βX . Berikut adalah persamaannya:

$$\Delta Y_t = c + \beta X_t + \left(\sum_{i=1}^p \alpha_i \Delta y_{t-i}\right) - \left(\sum_{i=1}^q \theta_i \epsilon_{t-i}\right) + \left(\sum_{j=1}^P \phi_j \Delta_s y_{t-j_s}\right) - \left(\sum_{j=1}^Q \theta_j \epsilon_{t-j_s}\right) + \epsilon_t \quad (12)$$

2.6 Metode Hyperparameter Tuning

Hyperparameter tuning merupakan tahap krusial dalam pengembangan model *machine learning* karena berperan dalam menentukan konfigurasi algoritma terbaik untuk meningkatkan kinerja model. Proses ini mencakup eksplorasi sistematis terhadap ruang *hyperparameter* untuk menemukan konfigurasi yang paling optimal. Jenis *hyperparameter* dapat bersifat kategorikal, diskrit, atau kontinu, masing-masing dapat mempengaruhi performa model dengan cara yang berbeda. Proses *tuning* bertujuan meminimalkan *loss function* model, sehingga menghasilkan performa prediksi yang lebih akurat baik untuk klasifikasi maupun regresi [27]. Berikut adalah metode umum yang digunakan untuk *hyperparameter tuning* [27]:

1. *Grid Search*

Grid search adalah metode penyetelan *hyperparameter* yang sistematis dan menyeluruh dengan mengeksplorasi semua kombinasi nilai *hyperparameter* dalam rentang yang ditentukan. Namun, *grid search* memiliki keterbatasan signifikan terkait tuntutan komputasi yang tinggi. Ketika jumlah *hyperparameter* dan nilai potensialnya bertambah, jumlah kombinasi yang harus dievaluasi tumbuh secara eksponensial, fenomena yang dikenal sebagai "*curse of dimensionality*." Hal ini membuat *grid search* kurang praktis atau tidak efisien untuk model dengan banyak *hyperparameter*, terutama jika sumber daya komputasi atau waktu terbatas.

2. *Random Search*

Random Search adalah metode alternatif yang efektif untuk mengatasi beban komputasi tinggi yang sering terjadi pada *grid search*. Berbeda dengan *grid search* yang mengevaluasi setiap kombinasi *hyperparameter* secara menyeluruh, *random search* menggunakan pendekatan stokastik dengan memilih subset kombinasi *hyperparameter* secara acak berdasarkan distribusi probabilitas tertentu. Metode ini cocok untuk ruang pencarian yang luas atau ketika sumber daya komputasi terbatas, terutama jika hanya sedikit *hyperparameter* yang berdampak signifikan terhadap kinerja model. Namun, sifat acak *random search* memiliki kelemahan, seperti potensi mengabaikan kombinasi *hyperparameter* tertentu yang mungkin optimal. Selain itu, tidak adanya pembelajaran dari evaluasi sebelumnya membuat *random search* kadang menghasilkan optimasi yang kurang maksimal dibandingkan pendekatan lain.

3. *Bayesian Optimization*

Bayesian Optimization menggunakan model *surrogate*, seperti *gaussian process*, sebagai *proxy* untuk fungsi objektif dalam penyetelan *hyperparameter*. Pendekatan ini sangat berguna dalam situasi di mana evaluasi model membutuhkan sumber daya yang besar. Dengan memanfaatkan model *surrogate*, *bayesian optimization* mengurangi jumlah percobaan yang diperlukan melalui eksplorasi ruang *hyperparameter* yang lebih efisien dan terfokus. Model *surrogate* memprediksi kinerja berbagai set *hyperparameter* berdasarkan data dari evaluasi sebelumnya, yang terus diperbarui seiring adanya data baru. Ini memungkinkan metode *bayesian optimization* untuk fokus pada kombinasi *hyperparameter* yang paling menjanjikan, sehingga mengurangi kebutuhan percobaan secara keseluruhan. Namun, metode ini memiliki tantangan terutama dalam hal penyiapan awal dan kebutuhan komputasi. Selain itu, permintaan komputasi meningkat, terutama jika jumlah *hyperparameter* yang dioptimalkan cukup banyak.

2.7 Evaluasi Model

Untuk mengukur akurasi dari sebuah model, beberapa metrik evaluasi model dapat digunakan untuk mengetahui tingkat akurasi dari sebuah model seperti *Root Mean Squared Error* (RMSE), *Mean Squared Error* (MSE), *Mean Absolute Percentage Error* (MAPE), dan *Mean Absolute Error* (MAE). Berikut penjelasan untuk keempat metrik tersebut [28], [29], [30], [31]:

1. *Root Mean Squared Error* (RMSE)

Root Mean Square Error (RMSE) adalah metode alternatif untuk evaluasi teknik peramalan yang digunakan untuk mengukur tingkat akurasi hasil perkiraan suatu model. Nilai RMSE sendiri adalah nilai rata-rata kuadrat dari jumlah kesalahan pada model prediksi. RMSE mudah

digunakan dan telah digunakan dalam banyak penelitian yang berkaitan dengan prediksi atau peramalan.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (13)$$

Keterangan:

$\hat{y}_i$: Nilai ramalan

y_i : Nilai aktual

n : Jumlah data

2. *Mean Squared Error (MSE)*

Mean Square Error (MSE) paling banyak digunakan dalam model regresi, dimana variabel independen yang menjadi targetnya nilai-nilai bersifat berkelanjutan. Hal ini diukur sebagai selisih kuadrat rata-rata antara keluaran aktual dan keluaran yang diperkirakan.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (14)$$

Keterangan:

y_i : Nilai aktual

$\hat{y}_i$: Nilai ramalan

n : Jumlah data

3. *Mean Absolute Percentage Error (MAPE)*

Mean Absolute Percentage Error (MAPE) mengukur keakuratan metode peramalan dengan menghitung kesalahan absolut sebagai persentase dari nilai aktual yang diamati. Ini memberikan indikasi yang jelas tentang seberapa besar penyimpangan nilai perkiraan dari nilai sebenarnya dalam persentase. MAPE dengan nilai <10% dianggap sangat akurat, 10-20% dianggap akurat, 20-50% kurang akurat, dan >50% tidak akurat.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (15)$$

Keterangan:

y_i : Nilai aktual

$\hat{y}_i$: Nilai ramalan

t : Periode waktu

n : Jumlah data

4. *Mean Absolute Error (MAE)*

Mean Absolute Error (MAE) dihitung menggunakan rata-rata nilai kesalahan dengan melihat selisih antara nilai aktual dengan nilai ramalan. MAE juga dikenal sebagai fungsi *loss* karena tujuan utama adalah meminimalkan nilai fungsi *loss* ini, yang dapat didefinisikan sebagai berikut.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (16)$$

Keterangan:

y_i : Nilai aktual
 $\hat{y}_i$: Nilai ramalan
 t : Periode waktu
 n : Jumlah data

2.8 Studi Literatur

Terdapat beberapa penelitian yang menggunakan metode Prophet dan SARIMAX dalam melakukan peramalan, yang dapat dilihat pada Tabel 2.

Tabel 2. Studi Literatur

No	Nama Peneliti	Model	Kontribusi	Area Aplikasi	Hasil
1	Yuhan Kuang [6]	Prophet	Melakukan peramalan penjualan alkohol di Amerika Serikat	Penjualan	Penelitian ini menunjukkan performa yang memuaskan dengan MAPE sebesar 0,05.
2	Bineet Kumar Jha dan Shilpa Pande [19]	Prophet, ARIMA, dan <i>Holt-Winter's</i>	Melakukan peramalan penjualan supermarket	Penjualan	Penelitian ini menunjukkan metode Prophet lebih unggul dari metode ARIMA dan <i>Holt-Winter's</i> dengan MSE sebesar 4.329,64, RMSE sebesar 65,8 dan MAPE sebesar 8,3%.
3	Marta Dmytryshyn [32]	SARIMAX, SARIMA	Melakukan peramalan penjualan makanan yang mudah rusak di industri retail	Penjualan	Penelitian ini menunjukkan SARIMAX lebih akurat dari SARIMA dengan nilai MAPE sebesar 18,94 dan RMSE sebesar 18,43.
4	Pooja Polina dan Swathi Ganesan [33]	SARIMAX, <i>deep learning</i>	Melakukan peramalan penjualan tractor	Penjualan	Penelitian ini menunjukkan hasil peramalan metode SARIMAX lebih unggul dari metode <i>deep learning</i> lainnya dengan

					nilai RMSE sebesar 0,01.
5	Muhammad Nana Trisolvena dan Marwah Masruroh [34]	Prophet, ARIMA, SARIMA, dan LSTM	Melakukan peramalan permintaan produk	Permintaan Produk	Penelitian ini menunjukkan hasil peramalan metode Prophet lebih unggul daripada metode lainnya dengan MAE sebesar 32.67, RMSE sebesar 44.85, dan MAPE 3.9%.

3. METODE PENELITIAN

Pada penelitian ini, metode penelitian yang digunakan adalah OSEM framework. OSEM (*Obtain, Scrub, Explore, Model, dan Interpret*) *Framework* adalah kerangka sistematis yang digunakan dalam ilmu data, terutama dalam menganalisis dan menafsirkan data. Metode ini terdiri dari lima langkah utama yang membantu peneliti mulai dari pengumpulan data hingga menghasilkan kesimpulan yang dapat diperbaiki. Berikut langkah-langkah dari OSEM *Framework* [35]:

1. *Obtain Data*
Langkah pertama dari metode ini adalah melakukan pengumpulan data dari berbagai sumber. Tujuannya adalah untuk memastikan bahwa data yang dikumpulkan akurat dan menyeluruh untuk analisis yang akan datang.
2. *Scrub Data*
Langkah selanjutnya adalah membersihkan dan mengolahnya data yang telah terkumpul menjadi sebuah informasi. Ini mencakup menghilangkan data yang tidak relevan atau bermasalah, menangani nilai yang hilang, dan memastikan bahwa kumpulan data di format dengan benar untuk analisis. Proses pembersihan ini sangat penting untuk meningkatkan kualitas data, yang berdampak pada kinerja pemodelan berikutnya.
3. *Explore Data*
Pada tahap ini, peneliti menganalisis data secara eksploratif dari data yang telah dibersihkan untuk menemukan pola, tren, dan wawasan. Analisis data eksploratif membantu memahami karakteristik data dan memberikan informasi tentang pilihan pemodelan yang akan dilakukan di masa mendatang. Tahap ini adalah langkah penting menuju wawasan data yang dapat ditindaklanjuti.
4. *Modelling Data*
Pada langkah ini, berbagai metode pemodelan dipilih untuk diterapkan pada data yang telah disediakan. Pemilihan model yang tepat sangat penting karena akan mempengaruhi tingkat akurasi dan efisiensi dari data yang di analisis.
5. *Interpret Data*
Langkah terakhir adalah menginterpretasikan hasil pemodelan. Ini melibatkan analisis keluaran model untuk mendapatkan kesimpulan dan pengetahuan penting yang dapat membantu pengambilan keputusan. Fase interpretasi harus memastikan bahwa hasil dapat diterapkan dan relevan bagi organisasi.

4. HASIL DAN PEMBAHASAN

Pada bagian ini, akan dibahas perbandingan antara model SARIMAX dan Prophet berdasarkan skenario pengujian, dengan fokus pada hasil evaluasi masing-masing model. Berikut adalah perbandingan kedua model berdasarkan hasil pengujian:

1. Perbandingan Model Pada Data Mingguan

Tabel 3. Perbandingan Evaluasi Model Pada Data Mingguan

Metrik	SARIMAX Tanpa Eksogen	SARIMAX Dengan Eksogen	Prophet Tanpa Eksogen	Prophet Dengan Eksogen
RMSE	0,38	0,40	0,40	0,40
MSE	0,15	0,16	0,16	0,16
MAE	0,28	0,31	0,30	0,32
MAPE	2,589%	2,808%	2,753%	2,922%

Tabel 3 menyajikan hasil evaluasi model SARIMAX dan Prophet pada data mingguan. Berdasarkan tabel tersebut, perbandingan performa antara model SARIMAX dan model Prophet dapat dilihat menjadi dua skenario, yaitu model tanpa faktor eksogen dan model dengan faktor eksogen. Pada model tanpa faktor eksogen, model SARIMAX memiliki performa yang lebih baik dengan nilai metrik RMSE, MSE, MAE, dan MAPE yang lebih rendah daripada model Prophet. Pada model dengan faktor eksogen, model SARIMAX juga lebih baik dengan metrik MAE dan MAPE yang lebih rendah dibandingkan model Prophet. Secara keseluruhan, model SARIMAX memiliki performa yang lebih baik dibandingkan model Prophet dalam peramalan data mingguan tanpa faktor eksogen dan dengan faktor eksogen. Namun, penggunaan faktor eksogen dalam peramalan model SARIMAX dan model Prophet tidak meningkatkan akurasi model dalam melakukan peramalan.

2. Perbandingan Model Pada Data Bulanan


Tabel 4. Perbandingan Evaluasi Model Pada Data Bulanan

Metrik	SARIMAX Tanpa Eksogen	SARIMAX Dengan Eksogen	Prophet Tanpa Eksogen	Prophet Dengan Eksogen
RMSE	0,16	0,16	0,16	0,17
MSE	0,03	0,03	0,03	0,03
MAE	0,12	0,13	0,14	0,13
MAPE	0,930%	1,030%	1,077%	1,045%

Berdasarkan Tabel 4, evaluasi model pada data bulanan menunjukkan bahwa model SARIMAX memiliki performa yang lebih baik dibandingkan dengan model Prophet, baik dengan atau tanpa faktor eksogen. Hal ini terlihat dari nilai MAPE model SARIMAX yang lebih rendah (0,930% untuk SARIMAX tanpa eksogen dan 1,030% untuk SARIMAX dengan eksogen) dibandingkan dengan model Prophet (1,077% untuk Prophet tanpa eksogen dan 1,045% untuk Prophet dengan eksogen). Secara keseluruhan, hasil ini menunjukkan bahwa model SARIMAX, baik dengan eksogen maupun tanpa eksogen, memberikan performa yang lebih baik dalam peramalan data bulanan dibandingkan dengan model Prophet. Namun, faktor eksogen dalam model Prophet dapat meningkatkan akurasi peramalan walaupun tidak signifikan.

Berdasarkan perbandingan hasil evaluasi model SARIMAX dan model prophet pada skenario mingguan dan bulanan, model SARIMAX menunjukkan kinerja yang lebih unggul dibandingkan model

Prophet dalam memprediksi penjualan menggunakan data penjualan tanpa faktor eksogen dan dengan faktor eksogen, terutama pada data bulanan dengan nilai MAPE terendah sebesar 0,930%.



Gambar 1. *Dashboard*

Dalam penelitian ini, *dashboard* yang disajikan pada Gambar 1 digunakan untuk memfasilitasi visualisasi analisis peramalan penjualan dengan menggunakan model SARIMAX dan Prophet. *Dashboard* dirancang dengan cermat untuk memberikan gambaran umum yang komprehensif tentang kinerja model peramalan dan untuk memungkinkan pengguna menginterpretasikan hasil analisis.

5. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, penelitian ini menghasilkan kesimpulan sebagai berikut:

1. Model Prophet dan SARIMAX mampu melakukan peramalan penjualan berdasarkan data *time series* dengan mempertimbangkan faktor eksternal. Hasil evaluasi performa model Prophet dan SARIMAX dalam peramalan penjualan menunjukkan bahwa model SARIMAX memiliki akurasi yang lebih baik dibandingkan model Prophet, baik pada data mingguan maupun bulanan. Hal ini dapat dilihat dari metrik evaluasi model SARIMAX yang memiliki nilai yang lebih rendah dibanding nilai metrik evaluasi model Prophet. Namun, penambahan faktor eksogen pada kedua model ini tidak memberikan dampak yang signifikan dalam meningkatkan performa model.
2. *Dashboard* yang mampu menampilkan visualisasi hasil peramalan secara informatif dan interaktif dapat memudahkan pengguna dalam menganalisis hasil peramalan dengan lebih baik sehingga dapat mendukung pengambilan keputusan bisnis yang cepat dan akurat.

6. SARAN

Berdasarkan penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya. Pertama, penggunaan dataset dengan cakupan yang lebih luas, baik dalam periode waktu yang lebih panjang maupun penambahan atribut data

lain, diharapkan dapat meningkatkan performa model peramalan. Kedua, penambahan faktor eksogen lain seperti data promosi, data cuaca, atau data terkait ekonomi juga dapat dipertimbangkan untuk meningkatkan akurasi model. Ketiga, eksplorasi rentang hyperparameter dan iterasi yang lebih luas dapat dilakukan untuk menemukan kombinasi parameter yang lebih optimal. Terakhir, pengembangan visualisasi pada dashboard, seperti penambahan fitur-fitur baru, dapat meningkatkan pengalaman pengguna dan memudahkan interpretasi hasil peramalan.

UCAPAN TERIMA KASIH

Penulis mengucapkan syukur yang sebesar-besarnya kepada Tuhan Yang Maha Esa atas berkat dan bimbingan-Nya, sehingga penulis dapat menyelesaikan penelitian ini dengan baik. Penulis menyampaikan terima kasih yang sebesar-besarnya kepada Bapak Roni Yunis, S.Kom., M.T. dan Ibu Elly, S.Kom., M.TI., selaku dosen pembimbing, atas bimbingan, nasihat, dan dukungan yang sangat berharga selama proses penelitian. Ucapan terima kasih juga disampaikan kepada Universitas Mikroskil atas penyediaan lingkungan akademis dan sumber daya yang memungkinkan terlaksananya penelitian ini dengan baik. Penulis menyadari ketidaksempurnaan karya ini dan mengundang umpan balik yang konstruktif untuk penyempurnaan di masa depan. Diharapkan penelitian ini dapat berkontribusi pada kemajuan pengetahuan dan aplikasi praktis di bidang peramalan penjualan dan analisis data.

DAFTAR PUSTAKA

- [1] R. Jeswani, "Predicting Walmart Sales, Exploratory Data Analysis, and Walmart Sales Dashboard," Rochester, Dec. 2021. Accessed: Oct. 06, 2024. [Online]. Available: <https://www.rit.edu/ischoolprojects/node/104009>
- [2] Y. Liu, "Sales Forecasting Based on Transformer-LSTM Model," in *5th International Conference on Computer Science and Intelligent Communication (CSIC 2023)*, Vancouver: Highlights in Science, Engineering and Technology, Mar. 2024, pp. 776–782. doi: 10.54097/qdavzg31.
- [3] A. Ramosaj, N. Ramosaj, and M. Widmer, "Improving Sales Forecasting by Combining Key Account Managers' Inputs and Models Such as SARIMA, LSTM, and Facebook Prophet," *Journal of Applied Business and Economics*, vol. 24, no. 6, pp. 11–22, Dec. 2022, doi: 10.33423/jabe.v24i6.5715.
- [4] C. Catal, B. Arslan, and A. Akbulut, "Benchmarking of Regression and Time Series Analysis Techniques for Sales Forecasting," *Balkan Journal of Electrical and Computer Engineering*, vol. 7, no. 1, pp. 20–26, Jan. 2019, doi: 10.17694/bajece.494920.
- [5] B. Pavlyshenko, "Machine-Learning Models for Sales Time Series Forecasting," *Data (Basel)*, vol. 4, no. 1, pp. 1–11, Jan. 2019, doi: 10.3390/data4010015.
- [6] Y. Kuang, "Time Series Data Forecasting: Alcohol Sales Prediction Based on Prophet," in *5th International Conference on Computer Science and Intelligent Communication (CSIC 2023)*, Vancouver: Highlights in Science, Engineering and Technology, Mar. 2024, pp. 597–601. doi: 10.54097/x446dk79.
- [7] E. Žunić, K. Korjenić, K. Hodzic, and D. Donko, "Application of Facebook's Prophet Algorithm for Successful Sales Forecasting Based on Real-world Data," *International Journal of Computer Science & Information Technology*, vol. 12, no. 2, pp. 23–36, Apr. 2020, doi: 10.5121/ijcsit.2020.12203.
- [8] S. Kwarteng and P. Andreevich, "Comparative Analysis of ARIMA, SARIMA and Prophet Model in Forecasting," *Research & Development*, vol. 5, no. 4, pp. 110–120, Oct. 2024, doi: 10.11648/j.rd.20240504.13.
- [9] A. Ramosaj, N. Ramosaj, and M. Widmer, "How to Improve Accessories Sales Forecasting of a Medium-Sized Swiss Enterprise? A Comparison Between Statistical Methods and Machine

- Learning Algorithms,” *Journal of Applied Business and Economics*, vol. 26, no. 4, pp. 145–167, Sep. 2024, doi: 10.33423/jabe.v26i4.7261.
- [10] F. Suprata, “Data Storytelling with Dashboard: Accelerating Understanding Through Data Visualization in Financial Technology Company Case Study,” *Jurnal METRIS*, vol. 20, no. 1, pp. 1–10, Jul. 2019, doi: 10.25170/metris.v20i1.2375.
- [11] F. Petropoulos *et al.*, “Forecasting: theory and practice,” *Int J Forecast*, vol. 38, no. 3, pp. 705–871, Jul. 2022, doi: 10.1016/j.ijforecast.2021.11.001.
- [12] K. Y. Wen, M. H. Joseph, and V. Sivakumar, “Big Mart Sales Prediction using Machine Learning,” *EAI Endorsed Transactions on Internet of Things*, vol. 10, pp. 1–6, Jun. 2024, doi: 10.4108/eetiot.6453.
- [13] R. Sen and S. Das, *Computational Finance with R*. Singapore: Springer Nature Singapore, 2023. doi: 10.1007/978-981-19-2008-0.
- [14] A. Nielsen, *Practical Time Series Analysis: Prediction with Statistics and Machine Learning*, First edition. Sebastopol, CA: O’Reilly Media, 2019. Accessed: Nov. 04, 2024. [Online]. Available: <https://www.oreilly.com/library/view/practical-time-series/9781492041641/>
- [15] Tableau, “Time Series Analysis: Definition, Types & Techniques | Tableau.” Accessed: Oct. 23, 2024. [Online]. Available: <https://www.tableau.com/analytics/what-is-time-series-analysis>
- [16] V. Kotu and B. Deshpande, “Time Series Forecasting,” in *Data Science*, Second Edition., Elsevier, 2019, ch. 12, pp. 395–445. doi: 10.1016/B978-0-12-814761-0.00012-5.
- [17] Meta Open Source, “Prophet | Forecasting at scale.” Accessed: Nov. 01, 2024. [Online]. Available: <https://facebook.github.io/prophet/>
- [18] J. Shen, D. Valagolam, and S. McCalla, “Prophet forecasting model: a machine learning approach to predict the concentration of air pollutants (PM_{2.5}, PM₁₀, O₃, NO₂, SO₂, CO) in Seoul, South Korea,” *PeerJ*, vol. 8, pp. 1–18, Sep. 2020, doi: 10.7717/peerj.9961.
- [19] B. K. Jha and S. Pande, “Time Series Forecasting Model for Supermarket Sales using FB-Prophet,” in *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)*, Erode: IEEE, Apr. 2021, pp. 547–554. doi: 10.1109/ICCMC51019.2021.9418033.
- [20] M. Lounis, “Predicting Active, Death and Recovery Rates of COVID-19 in Algeria Using Facebook’ Prophet Model,” Mar. 01, 2021, *Preprints 2021*. doi: 10.20944/preprints202103.0019.v1.
- [21] F. Oktavia and A. Witanti, “Implementasi Prophet Forecasting Model Dalam Prediksi Kualitas Udara Daerah Istimewa Yogyakarta,” *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, vol. 11, no. 1, pp. 64–74, 2024, doi: 10.35957/jatisi.v11i1.6804.
- [22] Meta Open Source, “Seasonality, Holiday Effects, And Regressors | Prophet.” Accessed: Nov. 03, 2024. [Online]. Available: https://facebook.github.io/prophet/docs/seasonality_holiday_effects_and_regressors.html#additional-regressors
- [23] Meta Open Source, “Diagnostics | Prophet.” Accessed: Nov. 03, 2024. [Online]. Available: <https://facebook.github.io/prophet/docs/diagnostics.html#cross-validation>
- [24] L. Döring, F. Grumbach, and P. Reusch, “Optimizing Sales Forecasts through Automated Integration of Market Indicators,” *ArXiv*, pp. 1–21, May 2024, doi: 10.48550/arXiv.2406.07564.
- [25] C. D. Mojica-Cabeza, C. E. García-Sánchez, R. Silva-Rodríguez, and L. García-Sánchez, “A review of the different boiler efficiency calculation and modeling methodologies,” *Informador Técnico*, vol. 86, no. 1, pp. 69–93, Oct. 2021, doi: 10.23850/22565035.3697.
- [26] T. Andrianajaina, D. T. Razafimahefa, R. Rakotoarijaina, and C. G. Haba, “Grid Search for SARIMAX Parameters for Photovoltaic Time Series Modeling,” *Global Journal of Energy Technology Research Updates*, vol. 9, pp. 87–96, Dec. 2022, doi: 10.15377/2409-5818.2022.09.7.
- [27] K. Khadka, J. Chandrasekaran, Y. Lei, R. N. Kacker, and D. R. Kuhn, “A Combinatorial Approach to Hyperparameter Optimization,” in *Proceedings of the IEEE/ACM 3rd International*

- Conference on AI Engineering - Software Engineering for AI*, New York, NY, USA: ACM, Apr. 2024, pp. 140–149. doi: 10.1145/3644815.3644941.
- [28] F. I. Sanjaya and D. Heksaputra, “Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short Term Memory,” *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, vol. 7, no. 2, pp. 163–174, Aug. 2020, doi: 10.35957/jatisi.v7i2.388.
- [29] C. Wiedyaningsih, E. Yuniarti, and N. P. V. Ginanti Putri, “Comparison of Forecasting Drug Needs Using Time Series Methods in Healthcare Facilities: A Systematic Review,” *Jurnal Farmasi Sains dan Praktis*, vol. 10, no. 2, pp. 156–165, Aug. 2024, doi: 10.31603/pharmacy.v10i2.11145.
- [30] H. Belyadi and A. Haghighat, *Machine Learning Guide for Oil and Gas Using Python*. Cambridge, MA: Elsevier, 2021. doi: 10.1016/C2019-0-03617-5.
- [31] 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*, pp. 1–24, Jul. 2021, doi: 10.7717/peerj-cs.623.
- [32] M. Dmytryshyn, “Development of a predictive model for sales forecasting of perishable food products,” Ukrainian Catholic University, 2023.
- [33] P. Polina, S. Ganesan, L. Karunarathne, and N. Somasiri, “Time Series Analysis for Tractor Sales using SARIMAX and Deep Learning Models,” *International Journal of Computer Communication and Informatics*, vol. 6, no. 1, pp. 27–57, Jul. 2024, doi: 10.34256/ijcci2413.
- [34] M. N. Trisolvena, M. Masruroh, and Y. M. Ginting, “Product Demand Forecast Analysis Using Predictive Models and Time Series Forecasting Algorithms on the Temu Marketplace Platform,” *International Journal Software Engineering and Computer Science (IJSECS)*, vol. 4, no. 2, pp. 430–439, Aug. 2024, doi: 10.35870/ijsecs.v4i2.2774.
- [35] S. Saleem, N. Hasan, A. Khattar, P. R. Jain, T. K. Gupta, and M. Mehrotra, “DeLTran15: A Deep Lightweight Transformer-based Framework for Multiclass Classification of Disaster posts on X,” *IEEE Access*, vol. 12, pp. 1–18, Oct. 2024, doi: 10.1109/ACCESS.2024.3478790.

