

Analisis Perbandingan Algoritma *Machine Learning* Untuk *Forecasting* Persediaan Produk Barang Pokok

<http://dx.doi.org/10.28932/jutisi.v10i2.9357>

Riwayat Artikel

Received: 8 Juli 2024 | Final Revision: 16 Juli 2024 | Accepted: 24 Juli 2024

Creative Commons License 4.0 (CC BY – NC)



Avinash [✉]#1, Andreas Widjaja^{#2}, Oscar Karnalim^{#3}

Program Studi Magister Ilmu Komputer, Universitas Kristen Maranatha, Bandung
Jl. Prof. Drg. Suria Sumantri No. 65, Bandung 40164, Indonesia

¹avinashawin48@gmail.com

²andreas.widjaja@maranatha.ac.id

³oscar.karnalim@maranatha.ac.id

✉Corresponding author: avinashawin48@gmail.com

Abstrak—Dalam era teknologi yang terus berkembang, permintaan konsumen terhadap kebutuhan sehari-hari semakin kompleks. Perusahaan ritel harus mengadopsi pendekatan canggih untuk memahami dan memenuhi preferensi konsumen. Penelitian ini mengeksplorasi efektivitas algoritma *machine learning* dalam *forecasting* persediaan barang pada berbagai jenis toko ritel menggunakan data historis transaksi pembayaran dan variabel terkait. Salah satu pendekatan yang digunakan adalah transformasi data menggunakan interval satu standar deviasi untuk menstasionerkan data, memastikan konsistensi statistik yang penting bagi algoritma prediksi. Hasil penelitian menunjukkan bahwa *Seasonal Autoregressive Integrated Moving Average* (SARIMA) memiliki kinerja terbaik dalam memprediksi persediaan barang baik untuk Usaha Mikro, Kecil, dan Menengah (UMKM) maupun ritel modern. Untuk data asli, *Mean Absolute Percentage Error* (MAPE) untuk UMKM adalah 1.11% dan untuk ritel modern adalah 0.98%. Untuk data yang dimodifikasi dengan interval satu standar deviasi, MAPE untuk UMKM adalah 0.74% dan untuk ritel modern adalah 0.70%. Hasil ini menunjukkan akurasi prediksi yang unggul, membantu perusahaan dalam menyesuaikan stok barang dengan lebih tepat sesuai dinamika pasar dan harapan konsumen. Penelitian ini diharapkan mampu memberikan pedoman solid untuk perbaikan strategi manajemen persediaan, sehingga perusahaan dapat menyiapkan stok barang dengan lebih tepat sesuai dinamika pasar dan harapan konsumen.

Kata kunci—Optimalisasi *Forecasting*; Perbandingan Algoritma; Ritel Modern; UMKM.

Comparative Analysis Of Machine Learning Algorithms For Forecasting Of Basic Goods Products

Abstract—In the era of continuously evolving technology, consumers' demands for everyday needs are becoming more complex. Retail companies must adopt sophisticated approaches to understand and meet consumer preferences. This research explores the effectiveness of *Machine Learning* algorithms in forecasting inventory levels in various types of retail stores using historical transaction payment data and related variables. One approach used is data transformation using one standard deviation interval to stationarize data,

ensuring statistical consistency that is important for prediction algorithms. The research results show that the Seasonal Autoregressive Integrated Moving Average (SARIMA) algorithm performs best in predicting inventory levels for both SMEs and modern retailers. For the original data, Mean Absolute Percentage Error (MAPE) for Small and Medium-sized Enterprises (SMEs) is 1.11% and for modern retailers is 0.98%. For data modified with one standard deviation interval, the MAPE for SMEs is 0.74% and for modern retailers is 0.70%. These results indicate superior prediction accuracy, helping companies adjust their inventory levels more accurately according to market dynamics and consumer expectations. This research is expected to provide a solid guideline for improving inventory management strategies, enabling companies to prepare inventory levels more accurately according to market dynamics and consumer expectations.

Keywords — Comparison Algorithms; Forecasting Optimization; Modern Retail; MSMEs.

I. PENDAHULUAN

UMKM (Usaha Mikro Kecil dan Menengah) merupakan sektor usaha produktif dengan skala kecil hingga menengah, sesuai definisi dalam Peraturan Pemerintah Nomor 7 Tahun 2021. UMKM memainkan peran penting dalam pertumbuhan ekonomi Indonesia, mencakup 99% dari seluruh unit usaha, berkontribusi 60,5% terhadap Produk Domestik Bruto (PDB), dan menyerap 96,9% tenaga kerja nasional [1]. Dalam era teknologi, kebutuhan konsumen terhadap produk dan layanan sehari-hari, termasuk barang pokok, semakin beragam. Untuk menghadapi tantangan ini, UMKM dan toko ritel modern perlu pendekatan canggih untuk memahami dan memenuhi preferensi konsumen secara efektif, mempertimbangkan perubahan tren, variasi permintaan pasar, dan kecepatan evolusi industri ritel.

Penggunaan algoritma *machine learning* terbukti efektif dalam melakukan *forecasting* persediaan produk pada UMKM dan toko ritel modern. Algoritma seperti *AutoRegressive Integrated Moving Average*(ARIMA), *Seasonal AutoRegressive Integrated Moving Average* (SARIMA), *Prophet*, *Support Vector Regression*(SVR), dan *Fast Fourier Transform*(FFT) menggunakan data historis transaksi pembayaran dan variabel relevan untuk mengidentifikasi pola pembelian barang. Ini memungkinkan UMKM dan toko ritel modern untuk mengantisipasi risiko kelebihan atau kekurangan stok. Penelitian ini diharapkan memberikan wawasan mendalam tentang efektivitas algoritma *machine learning* dalam *forecasting* persediaan produk barang pokok, sehingga perusahaan dapat meningkatkan efisiensi manajemen persediaan, menghadapi tantangan bisnis di era digital ini.

Hasbi Hassyddiqy dan Hasdiana [2] melakukan penelitian peramalan penjualan dan produksi pakaian pada usaha *Huebee* Indonesia menggunakan Metode ARIMA. Tujuannya adalah meningkatkan pelayanan produksi dengan merencanakan produksi yang tepat. Analisis data menggunakan metode *time series* dengan ARIMA menunjukkan peningkatan penjualan setiap bulan selama 3 bulan terakhir, namun item yang sudah banyak terjual cenderung mengalami penurunan dalam peramalan penjualan.

Nandia Rani Woro Tri Handayani et al. [3] mengembangkan sistem informasi otomatisasi bisnis untuk usaha mikro di Indonesia yang membiakkan dan menjual ikan lele. Mereka menggunakan model SARIMA untuk memprediksi penjualan ikan lele yang memiliki pola musiman unik. Sistem informasi Otomatisasi Bisnis untuk Usaha Mikro di Indonesia (SITRAN) dibuat *online* untuk memberikan fleksibilitas operasional. Hasil penelitian menunjukkan model SARIMAX (21,2,0) (1,0,0,12) memberikan RMSE terkecil dan merupakan model terbaik.

Suseno dan Suryo Wibowo [4] menggunakan metode ARIMA dan SARIMA untuk meramalkan penjualan produk "Telur Ayam Bahagia" oleh Agromix Lestari Group. Metode ARIMA digunakan untuk pola data yang tidak stasioner, sedangkan SARIMA dipilih khususnya untuk pola data yang bersifat musiman. Hasil penelitian menunjukkan penggunaan metode SARIMA menghasilkan *Mean Squared Error* (MSE) terendah sebesar 144.346, menandakan tingkat akurasi peramalan yang tinggi dalam penjualan telur ayam.

Feby Dinda Puspita Saria dan Lili Tanti [5] melakukan penelitian untuk PT. Industri Pembungkus Internasional, dengan fokus pada prediksi penjualan karton menggunakan model ARIMA. Perusahaan mengalami masalah dengan sistem semi komputerisasi yang membuat proses penghasilan keuntungan memakan waktu lama. Selain itu, terdapat masalah dalam penginputan data penawaran produk kardus yang tidak sesuai dengan harapan, yang mempengaruhi kesepakatan produk yang sudah terjadi. Penelitian ini bertujuan untuk menggunakan ARIMA dalam menghitung perkiraan stok produk karton, meningkatkan pencatatan perkiraan jumlah transaksi stok, dan mengatasi keterbatasan sistem semi komputerisasi yang mempengaruhi pembuatan laporan stok yang lama dan tidak akurat.

Cato Chandra dan Setia Budi [6] menguji akurasi prediksi pemasaran mahasiswa baru berdasarkan wilayah menggunakan metode *Prophet* dan ARIMA. Dengan *dataset* yang meliputi data aktual selama 26 tahun, mereka melakukan analisis peramalan deret waktu melalui *preprocessing* seperti transformasi logaritma dan *resampling*. Hasil penelitian menunjukkan Model *Prophet* unggul dibandingkan ARIMA berdasarkan nilai *Root Mean Squared Error*(RMSE).

Beno Jange [7] mengevaluasi prediksi harga saham Bank BCA menggunakan metode *Prophet*. Hasil penelitian menunjukkan tingkat akurasi prediksi yang baik, dengan nilai MAPE sebesar 5.37%. Meskipun demikian, terdapat sedikit

penurunan performa pada beberapa bulan tahun 2020 akibat dampak pandemi Covid-19. Penyetelan parameter hiper memainkan peran penting dalam meningkatkan kualitas prediksi, dengan penurunan *Mean Absolute Percentage Error* (MAPE) dari 9.06% menjadi 5.37%.

Zaeniah, Zaenudin, dan Bahtiar Imran [8] melakukan penelitian untuk memprediksi jumlah kunjungan wisatawan ke Provinsi Nusa Tenggara Barat (NTB) menggunakan metode *support vector regression*. Penelitian ini menghasilkan aplikasi prediksi kunjungan wisatawan berdasarkan *Event*, Bulan, dan Tahun, dengan hasil prediksi mendekati nilai aktual dalam kondisi normal, menggunakan data kunjungan wisatawan dari 2017 hingga 2021 dan event yang diselenggarakan selama periode yang sama.

Andrea Fumi et al. [9] membahas kompleksitas *forecasting* permintaan di industri mode, fokus pada pengaruh berbagai faktor seperti penjualan musiman, acara promosi, dan kondisi cuaca. Penelitian ini membandingkan algoritma *Fourier* dengan teknik lain berdasarkan data penjualan historis selama 4 tahun dari perusahaan mode Italia, menekankan bahwa analisis yang akurat dapat dilakukan tanpa perangkat lunak mahal.

Dyah Susilokarti et al. [10] melakukan penelitian untuk membandingkan akurasi prediksi curah hujan antara metode FFT, ARIMA, dan *Artificial Neural Network* (ANN). Kondisi iklim dan ketersediaan air yang optimal bagi pertumbuhan tanaman sangat penting dalam strategi budidaya yang efektif. Prediksi curah hujan diperlukan untuk memperkirakan kebutuhan air tanaman. Dengan variasi curah hujan yang tinggi saat ini, diperlukan pemodelan yang akurat untuk memprediksi kondisi curah hujan di masa depan. Evaluasi dilakukan berdasarkan MSE. Hasil penelitian menunjukkan nilai MSE untuk FFT adalah 14,92, ARIMA adalah 17,49, dan ANN adalah 0,07. Hasil ini menunjukkan bahwa ANN memiliki kinerja terbaik karena memiliki nilai MSE yang terkecil dibandingkan dengan metode lainnya

Laras Ervintyana Deni Kartika Sari et al. [11] melakukan penelitian tentang analisis penjualan dalam industri perusahaan. Penelitian ini menggunakan metode ARIMA, SVR, FFT, dan *Prophet* untuk peramalan penjualan, dengan menggunakan MAPE dan *Root Mean Squared Percentage Error* (RMSPE) sebagai ukuran akurasi. Hasil analisis menunjukkan bahwa ARIMA dan *Prophet* merupakan metode terbaik, dengan nilai MAPE dan RMSPE terendah. Analisis juga menunjukkan adanya pola berulang pada produk yang diteliti setiap kuartal.

Dienda Rizkya et al. [12] melakukan penelitian perbandingan algoritma ARIMA, Prophet, dan *Long Short-Term Memory* (LSTM) untuk menentukan algoritma yang cocok digunakan sebagai model prediksi penjualan tiket wisata di Saloka *Theme Park*. Data yang digunakan dalam penelitian ini adalah data historis penjualan tiket mulai dari 1 Januari 2020 hingga 24 April 2023. Data tersebut melalui beberapa proses seperti *pre-processing* untuk memastikan tidak ada *missing value*, diikuti dengan pengujian algoritma untuk menentukan tingkat akurasi masing-masing model. Hasil penelitian menunjukkan bahwa algoritma ARIMA menjadi algoritma dengan kinerja terbaik yang memiliki nilai RMSE sebesar 762.009 dan MAE sebesar 478.887.

Vika Putri Ariyanti dan Tristyanti Yusnitasari [13] membandingkan model ARIMA dan SARIMA untuk peramalan harga minyak mentah menggunakan data harian dari *Yahoo Finance* periode 27 Januari 2020 hingga 25 Januari 2023. Hasil evaluasi menunjukkan nilai RMSE yang sama untuk ARIMA dan SARIMA yaitu 1.905. Prediksi harga minyak untuk 7 hari kedepan menggunakan ARIMA adalah 86.230003 dan menggunakan SARIMA adalah 86.260002. Penelitian ini diharapkan dapat membantu pembuat kebijakan dalam menentukan kebijakan yang tepat terkait penggunaan minyak mentah.

Achmad Mauludiyanto et al. [14] bertujuan untuk mengeksplorasi pemodelan ARIMA dan deteksi *outlier* pada data curah hujan di Surabaya. Metode meliputi identifikasi stasioneritas data, evaluasi dengan transformasi *Box-Cox* untuk varians, dan analisis ACF untuk mean. ACF dan PACF digunakan untuk menentukan orde model ARIMA, diikuti dengan estimasi parameter dan diagnosa menggunakan uji *Ljung-Box* untuk *white noise* dan uji *Kolmogorov-Smirnov* untuk normalitas residual. Deteksi *outlier* dilakukan untuk meningkatkan akurasi prediksi, dengan implementasi menggunakan MINITAB dan MATLAB. Hasil penelitian menunjukkan integrasi deteksi *outlier* dapat mengurangi kesalahan prediksi (MSE) rata-rata sebesar 23,7%.

II. METODE PENELITIAN

Proses pertama penelitian dimulai dengan pengumpulan data secara *online* [15]. Data yang dikumpulkan berasal dari transaksi penjualan dan distribusi berbagai produk dari supplier dan distributor ke pelanggan. *Dataset* yang digunakan merupakan data transaksi penjualan harian dan distribusi berbagai macam produk dari tangan supplier dan distributor kepada pelanggan dari Desember 2020 hingga Desember 2021. Dataset ini terdiri dari 23 kolom dan 541.910 baris data. Setelah itu dilakukan pembersihan data dengan menghapus nilai negatif dalam kolom *Quantity* karena transaksi penjualan tidak mungkin menghasilkan jumlah barang negatif. Karakter tidak valid, seperti "-", juga dihilangkan karena diasumsikan sebagai kesalahan input transaksi atau format yang tidak sesuai. Transaksi dari jenis toko yang valid hanya Toko Kelontong, *Mini Market*, dan *Super Market*. Variabel yang tersisa setelah pembersihan data dan pra pemrosesan data adalah InvoiceDate, BARCODEID, PRODUCT_CATEGORY, Quantity, KOTA, PROVINSI, CHANNELID_SPLR, dan CHANNELNAME_SPLR. Kemudian data transaksi yang pada awalnya berbentuk harian diubah menjadi data mingguan dengan menambahkan *quantity* dari setiap

hari dalam periode seminggu, karena analisis menggunakan data bulanan akan menghasilkan terlalu sedikit data poin untuk analisis yang diinginkan. Untuk mengidentifikasi dan menghapus *outlier*, dapat menggunakan metode interval satu standar deviasi berdasarkan rata-rata dan standar deviasi data. Untuk menghitung batas *lower* dan *upper* dengan rumus:

$$\text{upper bound} = \mu + \sigma \quad (1)$$

$$\text{lower bound} = \mu - \sigma \quad (2)$$

Dimana μ adalah rata-rata data dan σ adalah standar deviasi data. Dengan metode ini, *outlier* yang berada di luar rentang tersebut dapat teridentifikasi dan terhapus, mempertahankan data yang tersisa dengan berasumsi jika data yang berada di dalam batas merupakan penjualan dalam keadaan normal tanpa adanya tren dan variasi dalam data dianggap wajar dan tidak sebagai *outlier*. Proses pembuatan model dalam salah satu jenis toko dilakukan dalam empat skenario berbeda. Pertama, prediksi dilakukan terhadap data testing 2 minggu terakhir dan hasilnya dibandingkan dengan data asli kedua terakhir dari keseluruhan dataset. Setelah itu, prediksi kembali dilakukan terhadap *data testing* yang sama, namun kali ini menggunakan data yang telah diproses menggunakan interval satu standar deviasi. Proses ini diulangi juga dengan langkah yang sama untuk prediksi 3 minggu terakhir.

Pembuatan model dilakukan dengan menggunakan enam algoritma *forecasting*, yaitu ARIMA, SARIMA, *prophet*, FFT, SVR. Untuk ARIMA dan SARIMA, menggunakan *auto_arima* yang terdapat pada *library pmdarima* untuk menemukan parameter terbaik (p, d, q) yang sesuai dengan data. Proses ini melibatkan iterasi melalui berbagai kombinasi parameter dan pemilihan model terbaik berdasarkan kriteria seperti AIC (*Akaike Information Criterion*), BIC (*Bayesian Information Criterion*), dan AICc (*corrected Akaike Information Criterion*) dan dilakukan *grid search*. *Grid search* ini secara otomatis menguji berbagai kombinasi parameter untuk menemukan model yang paling optimal berdasarkan nilai MAPE dan RMSPE. Hasil *grid search*, yang selalu mencari nilai MAPE dan RMSPE terkecil atau paling akurat.

Untuk *prophet*, tersedia *library fbprophet* yang memungkinkan untuk membuat model yang akurat dan dapat disesuaikan dengan fleksibilitas yang diperlukan untuk data yang kompleks seperti deteksi otomatis tren dan musim, serta penanganan liburan, berikut adalah parameter yang akan dipakai dalam pembuatan model *prophet*:

1. *growth*: Menentukan jenis pertumbuhan yang digunakan dalam model, bisa '*linear*' atau '*logistic*'.
2. *n_changepoints*: Jumlah titik perubahan tren yang akan dipertimbangkan oleh model.
3. *seasonality_mode*: Menentukan mode musiman yang digunakan, bisa '*additive*' atau '*multiplicative*'.
4. *yearly_seasonality*: Menentukan apakah komponen musiman tahunan akan diaktifkan.
5. *weekly_seasonality*: Menentukan apakah komponen musiman mingguan akan diaktifkan.
6. *daily_seasonality*: Menentukan apakah komponen musiman harian akan diaktifkan.
7. *holidays*: Menentukan apakah komponen hari libur akan dimasukkan dalam model.

Ketika membangun model *prophet* untuk data yang telah diubah dari harian menjadi mingguan, parameter *weekly_seasonality* sangat berkaitan karena memungkinkan model untuk secara otomatis menyesuaikan pola musiman yang terjadi setiap minggu dalam data waktu.

Sementara untuk FFT, penerapan algoritma dilakukan dengan langkah Pertama, panjang data pelatihan n dihitung, dan FFT diterapkan pada data tersebut menggunakan fungsi *fft* dari *library scipy.fft*. FFT mengubah data dari domain waktu menjadi domain frekuensi, menghasilkan *training_fft* yang merupakan representasi frekuensi dari data pelatihan. Selanjutnya, magnitudo dari FFT dihitung menggunakan fungsi *np.abs*, dan frekuensi-frekuensi yang sesuai dihitung dengan menggunakan *np.fft.fftfreq(n)*. Karena hasil FFT simetris, hanya setengah bagian frekuensi yang relevan, sehingga diambil hanya separuh frekuensi positif dan magnitudonya. Selanjutnya, nilai-nilai yang diramalkan dihitung dengan mengubah FFT kembali ke domain waktu menggunakan *ifft*, yang menghasilkan nilai-nilai ramalan dalam domain waktu. Untuk memperpanjang ramalan, dua nilai terakhir dari *forecasted_values* digabungkan ke dalam *forecast*. Proses ini memberikan prediksi berdasarkan analisis frekuensi data pelatihan menggunakan FFT.

Demikian pula, dalam pemodelan dengan menggunakan SVR, akan dilakukan pencarian parameter terbaik untuk kernel *sigmoid* dan *radial basis function* (RBF). Pengecualian dilakukan untuk kernel linear dan polynomial karena hasil evaluasi dengan metrik MAPE dan RMSPE menunjukkan nilai jutaan persen, sehingga dianggap tidak valid untuk digunakan dalam penelitian. Berikut adalah parameter penting yang dipakai dalam pemodelan SVR:

1. *Kernel* = ['*linear*', '*poly*', '*rbf*', '*sigmoid*'],
2. *C* = [0.001, 0.01, 0.1, 1, 10, 100]
3. *Gamma(y)* = ['*gamma*', '*scale*']
4. *Coef* = [0.0, 0.1, 0.5], hanya untuk *sigmoid*
5. *Epsilon(3)* = [0.0001, 0.001, 0.1, 1]

Dalam upaya menemukan model yang paling optimal, akan diterapkan metode *grid search* seperti yang dilakukan dalam pemodelan ARIMA dan SARIMA . Dengan tujuan yang sama yaitu, menguji berbagai kombinasi parameter untuk menentukan konfigurasi yang menghasilkan nilai *neg_mean_squared_error* dan *neg_mean_absolute_error* terkecil.

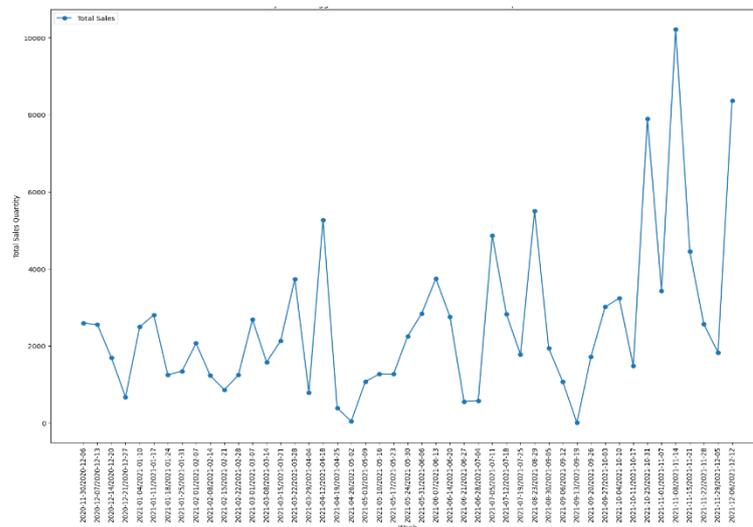
Setelah model-model tersebut dibangun, tahap selanjutnya adalah melakukan evaluasi terhadap setiap model. Evaluasi ini akan melibatkan perbandingan kinerja masing-masing model menggunakan metrik evaluasi MAPE dan RMSPE. Melalui evaluasi ini, akan diperoleh gambaran yang jelas mengenai kinerja setiap model dalam hal akurasi prediksi. Akhirnya, berdasarkan hasil evaluasi tersebut, akan ditarik rekomendasi dan kesimpulan mengenai kinerja tiap model, yang akan memberikan panduan dalam memilih model terbaik dalam *forecasting* persediaan barang di kedua jenis toko.

III. HASIL DAN PEMBAHASAN

A. Explore Data Analysis

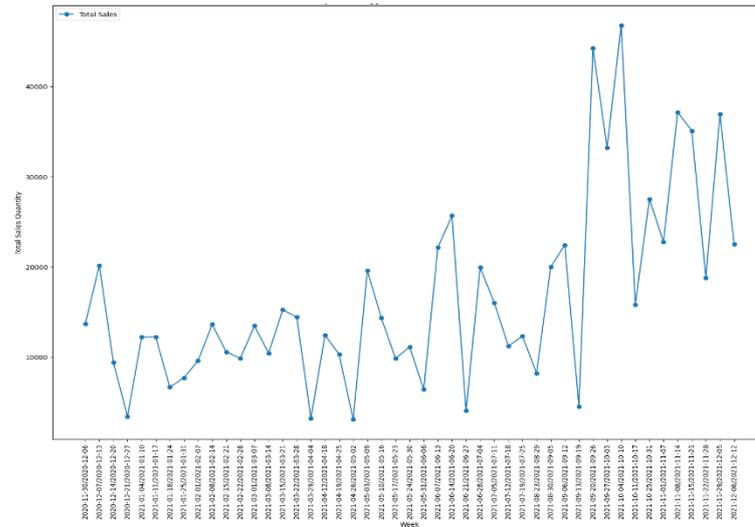
Exploratory Data Analysis (EDA) digunakan untuk mempermudah pemetaan dari *dataset* yang diperoleh, memberikan gambaran yang lebih jelas mengenai tujuan dan permasalahan yang dapat diidentifikasi dan dipecahkan. Melalui EDA, pola dapat dikenali dan hubungan antar variabel dalam data ditentukan.

Pada Gambar 1 memperlihatkan grafik penjualan mingguan produk barang pokok di jenis toko *supermarket* dan *minimarket*. Grafik ini menunjukkan fluktuasi penjualan dari akhir tahun 2020 hingga akhir tahun 2021, dengan beberapa puncak penjualan yang signifikan. Puncak penjualan tertinggi terjadi pada minggu ke-43 tahun 2021 dengan jumlah 10220 unit, disusul oleh puncak lainnya pada minggu ke-47 dengan 8.362 unit. Beberapa penurunan penjualan juga terlihat, seperti pada minggu ke-20 tahun 2021 dengan hanya 39 unit terjual. Data penjualan ini nantinya akan digunakan untuk pemodelan di toko ritel modern, dengan data testing untuk periode 2 minggu adalah 1827, 8362 dan periode 3 minggu adalah 2560, 1827, 8362.



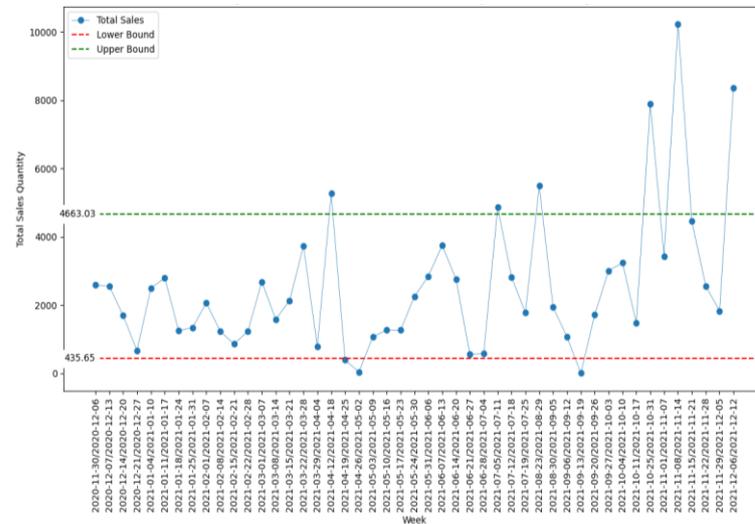
Gambar 1 Grafik Penjualan Mingguan Produk Barang Pokok di Jenis Toko *Supermarket* dan *Minimarket* (Ritel Modern)

Pada Gambar 2 memperlihatkan grafik penjualan mingguan produk barang pokok di jenis toko UMKM. Grafik ini menunjukkan variasi penjualan dari akhir tahun 2020 hingga akhir tahun 2021, dengan beberapa puncak penjualan yang mencolok. Puncak penjualan tertinggi terjadi pada minggu ke-39 tahun 2021 dengan jumlah 46.750 unit, diikuti oleh puncak lainnya pada minggu ke-37 dengan 44.200 unit. Ada juga beberapa penurunan penjualan yang signifikan, seperti pada minggu ke-4 tahun 2021 dengan hanya 3418 unit terjual. Data penjualan ini nantinya akan digunakan untuk pemodelan di toko UMKM, dengan data testing untuk periode 2 minggu adalah 36906, 22499 dan periode 3 minggu adalah 18767, 36906, 22499.



Gambar 2 Grafik Penjualan Mingguan Produk Barang Pokok di Jenis Toko Kelontong (UMKM)

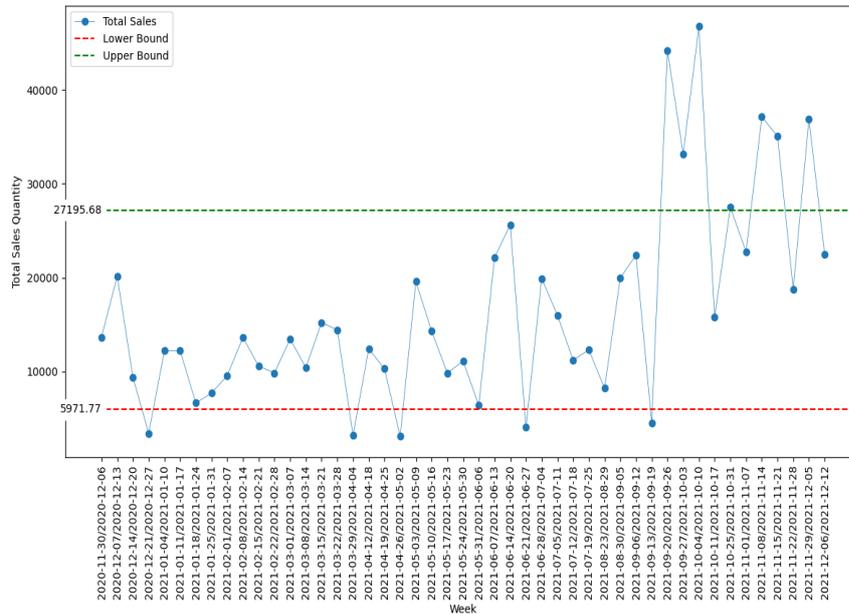
Pada Gambar 3 memperlihatkan grafik penjualan mingguan produk barang pokok di toko ritel modern yang telah dimodifikasi menggunakan interval satu standar deviasi. Grafik tersebut menunjukkan total kuantitas penjualan per minggu dari akhir tahun 2020 hingga akhir tahun 2021, dengan garis batas bawah (*Lower Bound*) dan garis batas atas (*Upper Bound*) yang masing-masing ditandai dengan garis putus-putus merah dan hijau. Nilai *Lower Bound* ditetapkan pada 435,65, sedangkan nilai *Upper Bound* berada pada 4663,03. Poin-poin data yang berada di luar batas ini menandakan anomali dalam penjualan mingguan. Data yang berada di luar batas interval satu standar deviasi ini telah diidentifikasi sebagai *outlier* dan akan dibuang dari analisis selanjutnya untuk memastikan bahwa analisis statistik yang dilakukan tidak terdistorsi oleh nilai-nilai yang ekstrem. Data penjualan ini nantinya akan digunakan untuk pemodelan di toko ritel modern dengan modifikasi, dengan data testing untuk periode 2 minggu adalah 2560, 1827 dan periode 3 minggu adalah 4452, 2560, 1827.



Gambar 3 Grafik Penjualan Mingguan Produk Barang Pokok di Jenis Toko Supermarket dan Minimarket menggunakan Interval satu standar deviasi (Ritel Modern)

Pada Gambar 4 memperlihatkan grafik penjualan mingguan produk barang pokok di jenis toko UMKM yang telah dimodifikasi menggunakan interval satu standar deviasi. Grafik tersebut menampilkan total kuantitas penjualan per minggu dari akhir tahun 2020 hingga akhir tahun 2021, dengan *Lower Bound* dan garis batas atas *Upper Bound* yang masing-masing ditandai dengan garis putus-putus merah dan hijau. Nilai *Lower Bound* ditetapkan pada 5971,77, sedangkan nilai *Upper Bound* berada pada 27195,68. Data yang berada di luar batas interval satu standar deviasi ini telah diidentifikasi sebagai

outlier dan akan dibuang dari analisis selanjutnya untuk memastikan bahwa analisis statistik yang dilakukan tidak terdistorsi oleh nilai-nilai yang ekstrem. Data penjualan ini nantinya akan digunakan untuk pemodelan di UMKM dengan modifikasi , dengan data testing untuk periode 2 minggu adalah 18767, 22499 dan periode 3 minggu adalah 22748, 18767, 22499.



Gambar 4 Grafik Penjualan Mingguan Produk Barang Pokok di Jenis Toko Kelontong menggunakan Interval satu standar deviasi (UMKM)

Setiap pemodelan dilakukan dua kali dengan tujuan membandingkan hasilnya menggunakan data yang asli dan data yang telah dibersihkan dari outlier menggunakan interval satu standar deviasi. Pendekatan pertama menggunakan data asli yang divisualisasikan pada Gambar 1 untuk toko ritel dan Gambar 2 untuk toko UMKM. Sementara pendekatan kedua menerapkan modifikasi dengan interval satu standar deviasi pada data, yang divisualisasikan dalam Gambar 3 untuk toko ritel dan Gambar 4 untuk toko UMKM.

B. ARIMA

Pembuatan model forecasting menggunakan ARIMA dimulai dengan Pengujian stasioner menggunakan ADF Test (*Augmented Dickey-Fuller Test*) dikarenakan model ARIMA mensyaratkan bahwa data yang digunakan stasioner. ADF Test membantu memastikan bahwa data tidak memiliki tren atau pola yang signifikan sehingga dapat dianalisis menggunakan model ARIMA secara efektif. Hasil ADF untuk toko ritel modern menunjukkan ADF Statistic sebesar -69.03, yang menunjukkan penjualan produk barang pokok di toko ritel modern bersifat stasioner. Hasil ADF untuk toko UMKM menunjukkan ADF Statistic sebesar -44.77, menunjukkan penjualan produk barang pokok di toko UMKM bersifat stasioner. Langkah selanjutnya yaitu pemilihan parameter p, d, dan q. Untuk mendapatkan nilai p, d, dan q yang optimal, digunakan Auto ARIMA. Perhitungan p, d, dan q dilakukan dengan rentang 0 sampai 3 menggunakan masing-masing kriteria informasi (AIC, BIC, dan AICc) dengan memakai *library pmdarima*. Selain itu, dilakukan *grid search* dengan forecasting 2 minggu ke depan dan 3 minggu ke depan untuk mengevaluasi kinerja model berdasarkan MAPE dan RMSPE terkecil.

Hasil analisis menunjukkan perbedaan dalam kompleksitas data antara toko ritel modern dan UMKM. Untuk toko ritel modern, model ARIMA (1,0,1) dipilih berdasarkan kriteria AIC, BIC, dan AICc, sedangkan hasil *grid search* memilih model ARIMA (0,0,1) untuk forecasting 2 dan 3 minggu ke depan. Penggunaan data interval satu standar deviasi tetap memilih model ARIMA (1,0,1), sementara *grid search* memilih ARIMA (3,2,2) untuk forecasting 2 minggu dan ARIMA (0,1,2) untuk forecasting 3 minggu.

Pada sisi lain, hasil untuk UMKM menunjukkan adanya persamaan kriteria. Untuk UMKM, kriteria AIC, BIC, dan AICc memilih model ARIMA (1,0,1), dan hasil *grid search* memilih model ARIMA (1,1,0) untuk forecasting 2 minggu dan ARIMA (2,0,0) untuk 3 minggu. Penggunaan interval satu standar deviasi menghasilkan model ARIMA (2,3,2) menurut kriteria AIC, BIC, dan AICc, namun *grid search* menunjukkan variasi, dengan model ARIMA (2,3,2) untuk forecasting 2 minggu dan ARIMA (3,3,3) untuk 3 minggu, menunjukkan kompleksitas data UMKM yang lebih tinggi dibandingkan toko ritel modern. Parameter p, d dan q yang sudah didapat ini kemudian diaplikasikan pada pelatihan model. Kemudian dilakukan perhitungan MAPE dan RMSPE untuk mengetahui performa forecasting ARIMA pada TABEL 1.

TABEL 1
HASIL MAPE DAN RMSPE ARIMA

| ARIMA(Ritel Modern) | | | | | | | | | |
|-------------------------------|--------|---------|--------|---------|--------|---------|------------|-----------|-----------|
| DATA ASLI | | | | | | | | | |
| | AIC | (1,0,1) | BIC | (1,0,1) | AICc | (1,0,1) | gridsearch | (0, 0, 1) | (0,0,0) |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | | 2 Week | 3 Week |
| MAPE | 68.02% | 71.96% | 68.02% | 71.96% | 68.02% | 71.96% | | 52.09% | 34.78% |
| RMSPE | 68.09% | 74.60% | 68.09% | 74.60% | 68.09% | 74.60% | | 55.37% | 45.21% |
| INTERVAL SATU STANDAR DEVIASI | | | | | | | | | |
| | AIC | (1,0,1) | BIC | (1,0,1) | AICc | (1,0,1) | gridsearch | (3, 2, 2) | (0, 1, 2) |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | | 2 Week | 3 Week |
| MAPE | 7.79% | 29.12% | 7.79% | 29.12% | 7.79% | 29.12% | | 0.69% | 24.49% |
| RMSPE | 8.05% | 31.63% | 8.05% | 31.63% | 8.05% | 31.63% | | 0.69% | 28.71% |
| ARIMA(UMKM) | | | | | | | | | |
| DATA ASLI | | | | | | | | | |
| | AIC | (1,0,1) | BIC | (1,0,1) | AICc | (1,0,1) | gridsearch | (1, 1, 0) | (2,0,0) |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | | 2 Week | 3 Week |
| MAPE | 20.21 | 31.76% | 20.21 | 31.76% | 20.21 | 31.76% | | 13.86% | 27.89% |
| RMSPE | 23.87% | 34.41% | 23.87% | 34.41% | 23.87% | 34.41% | | 18.57% | 34.44% |
| INTERVAL SATU STANDAR DEVIASI | | | | | | | | | |
| | AIC | (1,0,0) | BIC | (0,0,0) | AICc | (0,0,0) | gridsearch | (2, 3, 2) | (3,3,3) |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | | 2 Week | 3 Week |
| MAPE | 6.35% | 19.58% | 6.35% | 19.58% | 6.35% | 19.58% | | 6.35% | 8.24% |
| RMSPE | 6.43% | 21.25% | 6.43% | 21.25% | 6.43% | 21.25% | | 6.43% | 9.38% |

Analisis hasil ARIMA untuk toko ritel modern menunjukkan perbedaan yang signifikan antara data asli dan data yang telah melalui proses interval satu standar deviasi. Pada data asli, model ARIMA (1,0,1) dengan berbagai kriteria menunjukkan hasil yang konsisten, dengan AIC, BIC, dan AICc yang sama dalam rentang waktu 2 minggu dan 3 minggu. MAPE dan RMSPE juga menunjukkan hasil yang tinggi, yaitu sekitar 68% untuk model ARIMA (1,0,1). Model *grid search* (0,0,1) dan (0,0,0) menunjukkan hasil yang lebih baik dengan MAPE 52.09% dan 34.78%, serta RMSPE 55.37% dan 45.21%. Pada data ritel modern setelah interval satu standar deviasi, model ARIMA (1,0,1) menunjukkan hasil yang jauh lebih baik dengan MAPE dan RMSPE yang turun drastis menjadi sekitar 7.79% dan 8.05% masing-masing untuk 2 minggu dan 3 minggu. Model *grid search* (3,2,2) dan (0,1,2) bahkan menunjukkan MAPE dan RMSPE yang sangat rendah, yaitu 0.69% dan 28.71%.

Untuk data UMKM, analisis data asli menunjukkan bahwa model ARIMA (1,0,1) memiliki nilai AIC, BIC, dan AICc yang sama dalam rentang 2 minggu dan 3 minggu. MAPE untuk model ini adalah sekitar 20.21% dan RMSPE sekitar 23.87%. Model *grid search* (1,1,0) dan (2,0,0) memberikan hasil yang lebih baik dengan MAPE 13.86% dan 27.89%, serta RMSPE 18.57% dan 34.44%. Pada data UMKM setelah interval satu standar deviasi, model ARIMA (1,0,0) dan (0,0,0) memberikan hasil yang konsisten dengan MAPE dan RMSPE sekitar 6.35% dan 6.43%. Model *grid search* (2,3,2) dan (3,3,3) menunjukkan hasil yang lebih baik dengan MAPE 6.35% dan 8.24%, serta RMSPE 6.43% dan 9.38%. Dengan demikian, hasil ini menunjukkan bahwa interval satu standar deviasi memiliki dampak positif dalam meningkatkan akurasi prediksi model ARIMA, baik untuk toko ritel modern maupun toko UMKM.

C. SARIMA

Pemodelan menggunakan SARIMA secara garis besar mirip dengan menggunakan ARIMA dimana pada awalnya menggunakan Pengujian stasioner menggunakan ADF Test. Kemudian mencari parameter P, D dan Q dan p, d dan q yang paling optimal menggunakan AUTO ARIMA. sama seperti ARIMA, Perhitungan p, d, dan q dilakukan dengan rentang 0

sampai 3, tapi dengan SARIMA ditambah parameter baru P, D, Q dengan rentang yang sama. masing-masing menggunakan kriteria informasi (AIC, BIC, dan AICc) dengan memakai *library pmdarima*.

Hasil Analisis parameter SARIMA untuk jenis toko ritel modern menunjukkan adanya variasi dalam pemilihan model optimal dan evaluasi performa model. Dari data asli, model (0,0,0)(0,0,1)[4] terpilih sebagai yang paling optimal, sementara setelah modifikasi interval satu standar deviasi, model (0,1,0)(0,1,1)[4] menjadi pilihan terbaik. Hasil *grid search* menunjukkan model (1,1,3)(2,2,0)[4] untuk 2 minggu ke depan dan (0,0,0)(0,0,2)[4] untuk 3 minggu ke depan dari data asli. Setelah interval satu standar deviasi, model (3,2,2)(0,0,0)[4] terpilih untuk 2 minggu ke depan, sedangkan untuk 3 minggu ke depan, model (3,1,1)(1,2,3)[4] menjadi yang optimal.

Sementara itu, untuk jenis toko UMKM, hasil analisis menunjukkan model optimal adalah (1,0,0)(0,0,0)[4] dari data asli, sedangkan setelah interval satu standar deviasi, model (2,1,0)(0,1,1)[4] terpilih sebagai yang terbaik. Hasil *grid search* menunjukkan model (3,3,0)(2,1,3)[4] untuk 2 minggu ke depan dan (0,0,2)(0,2,0)[4] untuk 3 minggu ke depan dari data asli. Setelah interval satu standar deviasi, model (0,1,2)(2,1,0)[4] dipilih untuk 2 minggu ke depan, sedangkan untuk 3 minggu ke depan, model (2,3,2)(2,0,1)[4] menjadi optimal. Parameter yang sudah didapat ini kemudian diaplikasikan pada pelatihan model. Kemudian dilakukan perhitungan MAPE dan RMSPE untuk mengetahui performa *forecasting* SARIMA pada TABEL 2.

TABEL 2
HASIL MAPE DAN RMSPE SARIMA

| SARIMA(Ritel Modern) | | | | | | | | | |
|-------------------------------|--------|-------------------|--------|-------------------|--------|-------------------|-------------|-------------------|-------------------|
| DATA ASLI | | | | | | | | | |
| | AIC | (0,0,0)(0,0,1)[4] | BIC | (0,0,0)(0,0,1)[4] | AICc | (0,0,0)(0,0,1)[4] | gridsearch | (1,1,3)(2,2,0)[4] | (0,0,0)(0,0,2)[4] |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | | 2 Week | 3 Week |
| MAPE | 52.44% | 45.95% | 52.44% | 45.95% | 52.44% | 45.95% | | 0.98% | 20.96% |
| RMSPE | 52.59% | 46.65% | 52.59% | 46.65% | 52.59% | 46.65% | | 0.98% | 23.16% |
| INTERVAL SATU STANDAR DEVIASI | | | | | | | | | |
| | AIC | (0,1,0)(0,1,1)[4] | BIC | (0,1,0)(0,1,1)[4] | AICc | (0,1,0)(0,1,1)[4] | gridsearch | (3,2,2)(0,0,0)[4] | (3,1,1)(1,2,3)[4] |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | | 2 Week | 3 Week |
| MAPE | 79.37% | 32.72% | 79.37% | 32.72% | 79.37% | 32.72% | | 0.70% | 3.17% |
| RMSPE | 80.21% | 34.32% | 80.21% | 34.32% | 80.21% | 34.32% | | 0.70% | 3.77% |
| SARIMA(UMKM) | | | | | | | | | |
| DATA ASLI | | | | | | | | | |
| | AIC | (1,0,0)(0,0,0)[4] | BIC | (1,0,0)(0,0,0)[4] | AICc | (1,0,0)(0,0,0)[4] | Grid search | (3,3,0)(2,1,3)[4] | (0,0,2)(0,2,0)[4] |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | | 2 Week | 3 Week |
| MAPE | 52.15% | 33.57% | 52.15% | 33.57% | 52.15% | 33.57% | | 1.11% | 16.83% |
| RMSPE | 52.58% | 38.05% | 52.58% | 38.05% | 52.58% | 38.05% | | 1.11% | 17.72% |
| INTERVAL SATU STANDAR DEVIASI | | | | | | | | | |
| | AIC | (2,1,0)(0,1,1)[4] | BIC | (2,1,0)(0,1,1)[4] | AICc | (2,1,0)(0,1,1)[4] | Grid search | (0,1,2)(2,1,0)[4] | (2,3,2)(2,0,1)[4] |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | | 2 Week | 3 Week |
| MAPE | 21.69% | 17.04% | 21.69% | 17.04% | 21.69% | 17.04% | | 0.74% | 6.02% |

| | | | | | | | | |
|------------|-------|--------|-------|--------|-------|--------|-------|-------|
| RMS | 27.34 | 20.87% | 27.34 | 20.87% | 27.34 | 20.87% | 0.89% | 6.17% |
| PE | % | | % | | % | | | |

***Hasil yang didapatkan untuk rekomendasi adalah model dengan parameter (0,0,0)(0,0,0)[4]. Namun, hasil MAPE dan RMSPE serta hasil peramalan tidak valid. Oleh karena itu, rekomendasi tersebut diganti dengan parameter pada urutan rekomendasi kedua.

Hasil analisis performa model SARIMA untuk toko ritel modern Pada bagian data asli, model dengan parameter (0,0,0)(0,0,1)[4] menunjukkan nilai MAPE sebesar 52.44% dan RMSPE 52.59% untuk prediksi 2 minggu, serta MAPE 45.95% dan RMSPE 46.65% untuk prediksi 3 minggu. Model yang sama dengan kriteria AIC, BIC dan AICc menunjukkan hasil yang identik. Namun, model dengan parameter (1,1,3)(2,2,0)[4] memiliki performa yang jauh lebih baik untuk periode 2 minggu dengan MAPE dan RMSPE hanya sebesar 0.98%, tetapi performanya menurun signifikan untuk periode 3 minggu dengan MAPE 20.96% dan RMSPE 23.16%.

Pada bagian interval satu standar deviasi, performa model SARIMA diuji dengan konfigurasi berbeda untuk periode 2 minggu dan 3 minggu. Model dengan parameter (0,1,0)(0,1,1)[4] menunjukkan MAPE sebesar 79.37% dan RMSPE 80.21% untuk prediksi 2 minggu, untuk prediksi 3 minggu hasil signifikan ke arah yang lebih baik yaitu MAPE sebesar 32.72% dan RMSPE 34.32%. Sementara itu, model dengan parameter (3,2,2)(0,0,0)[4] menunjukkan performa yang jauh lebih baik dengan MAPE 0.70% dan RMSPE 0.70% untuk periode 2 minggu, serta model (3,1,1)(1,2,3)[4] dengan nilai MAPE 3.17% dan RMSPE 3.77% untuk periode 3 minggu. Hasil ini mengindikasikan bahwa pemilihan parameter model yang tepat sangat penting untuk meningkatkan akurasi prediksi, baik dalam data asli maupun interval satu standar deviasi. Model (1,1,3)(2,2,0)[4] dan (3,2,2)(0,0,0)[4] menunjukkan performa yang sangat baik dalam prediksi jangka pendek 2 minggu tetapi menurun untuk prediksi jangka menengah 3 minggu.

Berdasarkan tabel analisis SARIMA (UMKM) pada data asli, terlihat bahwa model dengan parameter (1,0,0)(0,0,0)[4] memberikan nilai MAPE dan RMSPE yang sama yaitu 52.15% dan 52.58% untuk prediksi 2 minggu, serta 33.57% dan 38.05% untuk prediksi 3 minggu. Model dengan parameter (3,3,0)(2,1,3)[4] dan (0,0,2)(0,2,0)[4] menunjukkan hasil prediksi yang lebih baik dengan MAPE 1.11% dan 16.83% untuk prediksi 2 minggu dan 3 minggu, serta RMSPE 1.11% dan 17.72%. Hal ini menunjukkan bahwa model dengan parameter tersebut memiliki tingkat akurasi yang lebih tinggi dibandingkan model lainnya dalam prediksi data asli.

Pada analisis dengan data yang di-Interval satu standar deviasi, model dengan parameter (2,1,0)(0,1,1)[4] memberikan nilai MAPE dan RMSPE sebesar 21.69% dan 27.34% untuk prediksi 2 minggu, serta 17.04% dan 20.87% untuk prediksi 3 minggu. Model dengan parameter (0,1,2)(2,1,0)[4] dan (2,3,2)(2,0,1)[4] menunjukkan performa yang lebih baik dengan MAPE 0.74% dan 6.02% untuk prediksi 2 minggu dan 3 minggu, serta RMSPE 0.89% dan 6.17%. Seperti hasil ritel modern, ini mengindikasikan bahwa normalisasi data dengan interval satu standar deviasi meningkatkan akurasi prediksi, terutama untuk model dengan parameter tertentu yang menghasilkan kesalahan prediksi yang sangat rendah.

D. Prophet

Pemodelan ketiga menggunakan algoritma *prophet*, pemodelan menggunakan algoritma prophet tidak memiliki banyak langkah seperti algoritma ARIMA dan SARIMA yang dimana terdapat proses pemilihan parameter yang terbaik. *Prophet* dapat langsung melatih model dengan menyesuaikan parameter ini sesuai dengan kenyataan yang terjadi di keadaan nyata. Pembuatan model dilakukan sebanyak empat kali untuk setiap jenis toko. Tiap jenis toko akan dilatih dengan dua skenario: satu dengan *weekly_seasonality* diaktifkan, dan yang lainnya tanpa aktivasi *weekly_seasonality*. Setelah itu, dilakukan *forecasting* untuk dua dan tiga minggu ke depan tiap skenario. Kemudian dilakukan perhitungan MAPE dan RMSPE untuk mengetahui performa *forecasting prophet* pada TABEL 3.

TABEL 3
HASIL MAPE DAN RMSPE PROPHET

| | Prophet(Retail Modern) | | | | Prophet(UMKM) | | | |
|-------|-------------------------------|--------|--------------------------|--------|---------------------------|--------|--------------------------|--------|
| | DATA ASLI | | | | | | | |
| | weekly_seasonality= False | | weekly_seasonality= True | | weekly_seasonality= False | | weekly_seasonality= True | |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week |
| MAPE | 80.58% | 72.12% | 80.58% | 72.12% | 24.05% | 31.10% | 27.39% | 19.09% |
| RMSPE | 84.80% | 77.81% | 84.80% | 77.81% | 24.32% | 32.40% | 32.93% | 25.47% |
| | INTERVAL SATU STANDAR DEVIASI | | | | | | | |
| | weekly_seasonality= False | | weekly_seasonality= True | | weekly_seasonality= False | | weekly_seasonality= True | |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week |
| MAPE | 20.53% | 28.50% | 20.53% | 28.50% | 8.86% | 17.79% | 64.25% | 73.18% |
| RMSPE | 28.91% | 32.53% | 28.91% | 32.53% | 11.83% | 19.30% | 64.32% | 73.22% |

Hasil analisis kinerja MAPE dan RMSPE dari skenario seasonal dan rentang waktu pengujian. Untuk toko ritel modern dengan data asli tanpa *weekly_seasonality*, MAPE dan RMSPE masing-masing sebesar 80.58% dan 84.80% pada rentang waktu 2 minggu, serta 72.12% dan 77.81% pada rentang waktu 3 minggu. Dengan *weekly_seasonality*, MAPE dan RMSPE turun menjadi 52.87% dan 55.48% pada rentang waktu 2 minggu, serta 38.35% dan 47.08% pada rentang waktu 3 minggu. Ketika menggunakan interval satu standar deviasi, hasil tanpa *weekly_seasonality* menunjukkan MAPE dan RMSPE sebesar 20.53% dan 28.91% pada rentang waktu 2 minggu, serta 28.50% dan 32.53% pada rentang waktu 3 minggu. Dengan *weekly_seasonality*, MAPE dan RMSPE meningkat menjadi 61.09% dan 61.48% pada rentang waktu 2 minggu, serta 84.37% dan 84.55% pada rentang waktu 3 minggu.

Untuk UMKM dengan data asli tanpa *weekly_seasonality*, MAPE dan RMSPE masing-masing sebesar 24.05% dan 24.32% pada rentang waktu 2 minggu, serta 31.10% dan 32.40% pada rentang waktu 3 minggu. Dengan *weekly_seasonality*, MAPE dan RMSPE sebesar 27.39% dan 32.93% pada rentang waktu 2 minggu, serta 19.09% dan 25.47% pada rentang waktu 3 minggu. Pada penggunaan interval satu standar deviasi, hasil tanpa *weekly_seasonality* menunjukkan MAPE dan RMSPE sebesar 8.86% dan 11.83% pada rentang waktu 2 minggu, serta 17.79% dan 19.30% pada rentang waktu 3 minggu. Dengan *weekly_seasonality*, MAPE dan RMSPE sebesar 64.25% dan 64.32% pada rentang waktu 2 minggu, serta 73.18% dan 73.22% pada rentang waktu 3 minggu.

Dari hasil tersebut, performa *forecasting* prophet pada data asli cenderung memiliki nilai akurasi yang bervariasi, baik pada skenario *weekly_seasonality* menjadi *True* maupun *False*. Data asli bersifat seasonal, yang menyebabkan variasi musiman mempengaruhi hasil prediksi dan meningkatkan kesalahan. Sebaliknya, penggunaan interval satu standar deviasi membuat data menjadi stasioner, menghilangkan komponen musiman dan trend sehingga model prophet dapat memprediksi dengan lebih akurat. Namun, ketika *weekly_seasonality* diaktifkan, hasil prediksi pada data interval satu standar deviasi menjadi kurang akurat. Hal ini disebabkan karena penambahan komponen musiman pada data yang sudah distasionerkan justru memperkenalkan variasi baru yang tidak sesuai dengan sifat stasioner data tersebut. Hal ini menunjukkan bahwa untuk data yang sudah distasionerkan, prophet memberikan hasil prediksi yang lebih baik tergantung dari pengaturan seasonalitynya.

E. Support Vector Regression(SVR)

Pada skenario SVR untuk ritel modern dengan data asli, dua kernel yang digunakan adalah RBF dan *sigmoid*. Untuk kernel RBF, parameter terbaik untuk prediksi dua minggu ke depan dengan metrik *neg_mean_squared_error* adalah {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'}, sedangkan untuk tiga minggu ke depan adalah {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'}. Dalam hal *neg_mean_absolute_error*, parameter terbaik untuk dua dan tiga minggu ke depan sama-sama adalah {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'}. Untuk kernel *sigmoid*, terdapat keseragaman parameter terbaik dengan metrik *neg_mean_squared_error* dan *neg_mean_absolute_error* yaitu {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} untuk dua dan tiga minggu ke depan. Hasil ini menunjukkan bahwa penggunaan nilai *epsilon* yang rendah lebih efektif dalam meminimalkan kesalahan pada prediksi data ritel modern pada metrik RBF maupun *sigmoid*.

Ritel modern dengan modifikasi interval satu standar deviasi memiliki hasil terbaik untuk kernel RBF dengan metrik *neg_mean_squared_error* adalah {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} untuk dua minggu dan tiga minggu ke depan. Dalam metrik *neg_mean_absolute_error*, parameter terbaik adalah {'C': 100, 'epsilon': 1, 'gamma': 'scale',

'kernel': 'rbf'} untuk dua minggu, dan {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} untuk tiga minggu ke depan. Untuk kernel *sigmoid* dengan metrik *neg_mean_squared_error*, parameter terbaik adalah {'C': 0.001, 'coef0': 0.5, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} untuk dua minggu dan {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} untuk tiga minggu ke depan. Sedangkan untuk metrik *neg_mean_absolute_error*, parameter terbaik adalah {'C': 0.001, 'coef0': 0.5, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} untuk dua minggu dan {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} untuk tiga minggu ke depan.

Untuk SVR pada data asli UMKM, kernel RBF menunjukkan parameter terbaik dengan metrik *neg_mean_squared_error* sebagai {'C': 10, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'} baik untuk dua maupun tiga minggu ke depan. Sama seperti metrik *neg_mean_squared_error*, metrik *neg_mean_absolute_error* memiliki kesamaan parameter terbaik untuk dua minggu dan tiga minggu, yaitu {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'}. Pada kernel *sigmoid*, parameter terbaik dengan metrik *neg_mean_squared_error* adalah {'C': 0.001, 'coef0': 0.5, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} untuk dua minggu dan untuk tiga minggu ke depan adalah {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'}. Sedangkan metrik *neg_mean_absolute_error*, memiliki parameter terbaik yang sama dengan metrik *neg_mean_squared_error* yaitu {'C': 0.001, 'coef0': 0.5, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} dan {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} baik untuk dua maupun tiga minggu ke depan.

Pada skenario dengan modifikasi interval satu standar deviasi untuk data UMKM, kernel RBF dengan metrik *neg_mean_squared_error* menghasilkan parameter terbaik yang seragam untuk dua dan tiga minggu kedepan yaitu {'C': 100, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'}. Serupa dengan metrik *neg_mean_squared_error*, metrik *neg_mean_absolute_error* memiliki parameter terbaik yang serupa untuk dua minggu dan untuk tiga minggu ke depan yakni ialah {'C': 100, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'}. Untuk kernel *sigmoid*, metrik *neg_mean_squared_error* dan *neg_mean_absolute_error* mempunyai 1 parameter terbaik yang sama persis untuk setiap skenario waktu minggu kedepan, yaitu {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'}. Kesimpulannya, Keseragaman parameter terbaik yang ditemukan untuk kedua kernel dan untuk kedua metrik evaluasi menunjukkan bahwa konfigurasi model yang optimal cenderung stabil dan tidak terlalu dipengaruhi oleh perubahan matrik evaluasi atau perbedaan jangka waktu prediksi. Kemudian dilakukan perhitungan MAPE dan RMSPE untuk mengetahui performa *forecasting* SVR pada TABEL 4.

TABEL 4
HASIL MAPE DAN RMSPE SVR

| SVR(Retail Modern) | | | | | | | | | |
|-------------------------------|--|---|--|--|---------------------|---|--|---|--|
| DATA ASLI | | | | | | | | | |
| RB F | <i>neg_mean_squared_e rror</i> | | <i>neg_mean_absolute_e rror</i> | | <i>SIGMOI D</i> | <i>neg_mean_squared_e rror</i> | | <i>neg_mean_absolute_e rror</i> | |
| paramet er | {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} | {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'} | {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} | {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} | | {'C': 100, 'coef0': 100, 'epsilon': 0.0, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 0.0001, 'auto', 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 0.0001, 'auto', 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 100, 'epsilon': 0.0, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 0.0001, 'auto', 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 100, 'epsilon': 0.0, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 0.0001, 'auto', 'gamma': 'auto', 'kernel': 'sigmoid'} |
| | 2 Week | 3 Week | 2 Week | 3 Week | | 2 Week | 3 Week | 2 Week | 3 Week |
| MAPE | 44.14% | 35.81% | 44.14% | 35.81% | | 44.14% | 35.81% | 44.14% | 35.81% |
| RMSPE | 54.04% | 46.03% | 54.04% | 46.03% | | 54.04% | 46.03% | 54.04% | 46.03% |
| INTERVAL SATU STANDAR DEVIASI | | | | | | | | | |
| RB F | <i>neg_mean_squared_e rror</i> | | <i>neg_mean_absolute_e rror</i> | | <i>SIGMOI D</i> | <i>neg_mean_squared_e rror</i> | | <i>neg_mean_absolute_e rror</i> | |
| paramet er | {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} | {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} | {'C': 100, 'epsilon': 1, 'gamma': 'scale', 'gamma': 'auto', 'kernel': 'rbf'} | {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} | | {'C': 0.001, 'coef0': 0.5, 'epsilon': 0.0001, 'gamma': 0.0001, 'auto', 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 0.0001, 'auto', 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 0.001, 'coef0': 0.5, 'epsilon': 0.0001, 'gamma': 0.0001, 'auto', 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 0.0001, 'auto', 'gamma': 'auto', 'kernel': 'sigmoid'} |

| | 'kernel': 'rbf'} | 'kernel': 'rbf'} | 'kernel': 'rbf'} | 'kernel': 'rbf'} | 'gamma': 'auto', 'kernel': 'sigmoid'} | 'gamma': 'auto', 'kernel': 'sigmoid'} | 'gamma': 'auto', 'kernel': 'sigmoid'} | 'gamma': 'auto', 'kernel': 'sigmoid'} |
|--------------------------------------|--|---|--|--|--|--|--|--|
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week |
| MAPE | 14.52% | 31.37% | 14.41% | 31.37% | 14.52% | 31.37% | 14.52% | 31.37% |
| RMSPE | 19.54% | 39.10% | 20.30% | 39.10% | 19.54% | 39.10% | 19.54% | 39.10% |
| SVR(UMKM) | | | | | | | | |
| DATA ASLI | | | | | | | | |
| | RB F | neg_mean_squared_e rror | neg_mean_absolute_e rror | SIGMOI D | neg_mean_squared_e rror | neg_mean_absolute_e rror | neg_mean_squared_e rror | neg_mean_absolute_e rror |
| paramet er | {'C': 10, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'} | {'C': 10, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'} | {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} | {'C': 0.001, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} | {'C': 0.001, 'coef0': 0.5, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 0.001, 'coef0': 0.5, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week |
| MAPE | 51.62% | 45.94% | 51.88% | 46.17% | 51.88% | 46.17% | 51.88% | 46.17% |
| RMSPE | 52.94% | 48.07% | 53.17% | 48.27% | 53.17% | 48.27% | 53.17% | 48.27% |
| INTERVAL SATU STANDAR DEVIASI | | | | | | | | |
| | RB F | neg_mean_squared_e rror | neg_mean_absolute_e rror | SIGMOI D | neg_mean_squared_e rror | neg_mean_absolute_e rror | neg_mean_squared_e rror | neg_mean_absolute_e rror |
| paramet er | {'C': 100, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'} | {'C': 100, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'} | {'C': 100, 'epsilon': 0.0001, 'gamma': 'scale', 'kernel': 'rbf'} | {'C': 100, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'rbf'} | {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} | {'C': 100, 'coef0': 0.0, 'epsilon': 0.0001, 'gamma': 'auto', 'kernel': 'sigmoid'} |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week |
| MAPE | 38.66% | 41.03% | 38.66% | 41.36% | 39.30% | 41.61% | 39.30% | 41.61% |
| RMSPE | 39.06% | 41.38% | 39.06% | 41.70% | 39.68% | 41.95% | 39.68% | 41.95% |

Hasil perhitungan MAPE dan RMSPE pada pemodelan SVR. Untuk data asli ritel modern, model SVR dengan kernel RBF menghasilkan MAPE sebesar 44.14% untuk prediksi 2 minggu dan 35.81% untuk prediksi 3 minggu. RMSPE untuk kernel ini adalah 54.04% untuk 2 minggu dan 46.03% untuk 3 minggu. Kernel *sigmoid* memberikan hasil yang sama persis untuk MAPE dan RMSPE dengan nilai yang identik. Analisis dan kesimpulan menunjukkan bahwa kernel RBF dan *sigmoid* tidak menunjukkan perbedaan performa yang signifikan pada data asli ritel modern. Namun, prediksi untuk periode 3 minggu memberikan hasil yang lebih akurat dibandingkan dengan periode 2 minggu, ditunjukkan oleh penurunan nilai MAPE dan RMSPE.

Pada data ritel modern yang dinormalisasi dengan interval satu standar deviasi, kernel RBF menghasilkan MAPE sebesar 14.52% untuk metrik *neg_mean_squared_error* dan 14.41% untuk metrik *neg_mean_absolute_error* dalam periode 2

minggu dan 31.37% untuk 3 minggu, dengan RMSPE masing-masing 19.54% dan 20.30% untuk 2 minggu sert 39.10% untuk 3 minggu . Kernel *sigmoid* menunjukkan hasil MAPE dan RMSPE yang identik dengan kernel RBF. Analisis menunjukkan bahwa normalisasi dengan interval satu standar deviasi secara signifikan meningkatkan akurasi prediksi, seperti yang ditunjukkan adanya penurunan besar untuk periode 2 minggu dalam nilai MAPE dan RMSPE dibandingkan dengan data asli. Namun, untuk periode 3 minggu, akurasi prediksi menurun,tetapi masih menghasilkan angka prediksi yang lebih baik walaupun tidak signifikan dibandingkan dengan data asli.

Untuk data asli UMKM, hasil menunjukkan bahwa metrik *neg_mean_squared_error* memiliki nilai akurasi yang lebih baik dibandingkan dengan metrik *neg_mean_absolute_error* yaitu MAPE 51.62% dan RMSPE 52.94% untuk periode 2 minggu dan MAPE 45.94% dan RMSPE 48.07% untuk periode 3 minggu. Kernel *sigmoid* menunjukkan hasil yang sedikit lebih tinggi dengan MAPE 51.88% dan RMSPE 53.17% untuk periode 2 minggu serta MAPE 46.17% dan RMSPE 48.27% untuk periode 3 minggu. Dari hasil ini, dapat disimpulkan bahwa kernel RBF sedikit lebih unggul dalam hal prediksi.

Pada data UMKM yang telah dinormalisasi dengan interval satu standar deviasi, terdapat kemiripan dengan data asli dimana metrik *neg_mean_squared_error* kembali lebih unggul dengan MAPE 38.66% dan RMSPE 39.06% untuk periode 2 minggu dan MAPE 41.03% dan RMSPE 41.38% untuk periode 3 minggu. Untuk kernel *sigmoid*, hasil menunjukkan bahwa MAPE untuk 2 minggu adalah 39.30% dan untuk 3 minggu adalah 41.61%, sementara RMSPE adalah 39.68% dan 41.95% untuk masing-masing periode.Dari hasil ini, dapat disimpulkan bahwa normalisasi interval satu standar deviasi secara signifikan meningkatkan akurasi prediksi untuk periode 2 minggu dibandingkan dengan data asli, sebagaimana ditunjukkan oleh penurunan nilai MAPE dan RMSPE. Namun, perbaikan ini tidak sebesar pada periode prediksi 3 minggu, di mana performa kernel RBF dan *sigmoid* relatif sama.

F. Fast Fourier Transform(FFT)

Pemodelan *forecasting* Terakhir menggunakan Algoritma FFT , pemodelan akan dilakukan 4 kali antara tiap jenis toko yaitu memakai data asli dengan *forecasting* 2 dan 3 minggu kedepan dan dengan modifikasi interval satu standar deviasi dengan *forecasting* 2 dan 3 minggu kedepan juga.Langkah pertama dalam pemodelan FFT melibatkan analisis data penjualan untuk memahami pola frekuensi yang ada. Analisis frekuensi dari data penjualan toko ritel modern menunjukkan bahwa komponen frekuensi terendah memiliki magnitudo terbesar, sekitar 100000, menunjukkan dominasi tren jangka panjang. Setelah data dimodifikasi dengan interval satu standar deviasi, frekuensi terendah tetap dominan dengan magnitudo sekitar 70000, sementara frekuensi lainnya menunjukkan variasi periodik yang lebih kecil.

Untuk toko UMKM, analisis frekuensi juga menunjukkan dominasi tren jangka panjang dengan magnitudo frekuensi terendah sekitar 700000. Setelah modifikasi dengan interval satu standar deviasi, frekuensi terendah memiliki magnitudo antara 400000 hingga 450000, dan frekuensi lainnya menunjukkan variasi periodik yang lebih kecil.

Setelah dilakukan analisis terhadap pola frekuensi maka langkah selanjutnya adalah mengimplementasikan rumus pemodelan Algoritma FFT pada model toko UMKM dan toko ritel sehingga menghasilkan MAPE dan RMSPE.Hasil dapat terlihat pada TABEL 5.

TABEL 5
HASIL MAPE DAN RMSPE FFT

| | FFT(Retail Modern) | | FFT(UMKM) | |
|--------------|-------------------------------|---------|-----------|--------|
| | DATA ASLI | | | |
| | 2 Week | 3 Week | 2 Week | 3 Week |
| MAPE | 106.53% | 180.03% | 10.79% | 25.89% |
| RMSPE | 112.82% | 267.32% | 12.25% | 34.50% |
| | INTERVAL SATU STANDAR DEVIASI | | | |
| | 2 Week | 3 Week | 2 Week | 3 Week |
| MAPE | 88.81% | 52.45% | 8.49% | 20.50% |
| RMSPE | 104.39% | 58.39% | 11.25% | 21.73% |

Untuk FFT ritel modern dengan data asli, MAPE dan RMSPE untuk periode 2 minggu masing-masing sebesar 106,53% dan 112,82%, sedangkan untuk periode 3 minggu masing-masing sebesar 180,03% dan 267,32%. Setelah normalisasi menggunakan interval satu standar deviasi, terjadi penurunan kesalahan dimana MAPE dan RMSPE untuk periode 2 minggu menjadi 88,81% dan 104,39%, serta untuk periode 3 minggu menjadi 52,45% dan 58,39%.Untuk FFT UMKM dengan data asli , MAPE dan RMSPE untuk periode 2 minggu masing-masing sebesar 10,79% dan 12,25%, sedangkan untuk periode 3

minggu masing-masing sebesar 25,89% dan 34,50%. Dengan normalisasi interval satu standar deviasi, MAPE dan RMSPE untuk periode 2 minggu turun menjadi 8,49% dan 11,25%, serta untuk periode 3 minggu menjadi 20,50% dan 21,73%.

Hasil ini menunjukkan bahwa normalisasi interval satu standar deviasi meningkatkan akurasi ramalan untuk kedua dataset, yang ditunjukkan oleh penurunan nilai MAPE dan RMSPE. Selain itu, periode ramalan yang lebih panjang cenderung menghasilkan kesalahan yang lebih besar, yang merupakan hal yang wajar dalam *forecasting*. Dibandingkan dengan FFT UMKM, FFT Retail Modern memiliki kesalahan yang jauh lebih tinggi, mengindikasikan bahwa *forecasting* untuk dataset ritel modern memiliki variabilitas dan trend yang lebih bervariasi. Secara keseluruhan, normalisasi interval satu standar deviasi efektif dalam meningkatkan akurasi ramalan, terutama pada *dataset* yang memiliki variabilitas tinggi seperti *dataset* ritel modern.

G. Evaluasi dan Perbandingan Kinerja Antar Model

Setelah Masing-masing pembentukan model *forecasting* telah dibentuk dilakukan perbandingan kinerja model untuk akurasi MAPE dan RMSPE terbaik antara model, TABEL 6 menunjukkan parameter terbaik dari setiap model untuk setiap skenario dari toko UMKM dan toko ritel modern

TABEL 6
HASIL MAPE DAN RMSPE TERBAIK UNTUK SETIAP MODEL

| Perbandingan Kinerja Retail Modern | | | | | | | | | | | |
|------------------------------------|-----------|-----------|-------------------|-------------------|----------------------------------|---------------------------------|--------------------------------------|---------|----------|----------|--|
| DATA ASLI | | | | | | | | | | | |
| | ARIMA | | SARIMA | | PROPHET | | SVR | | FFT | | |
| parameter terbaik | (0, 0, 1) | (0, 0, 1) | (1,1,3)(2,2,0)[4] | (0,0,0)(0,0,2)[4] | <i>weekly_seasonality</i> =True | | kernel <i>sigmoid</i> dan <i>rbf</i> | | | | |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | |
| MAPE | 52.09 % | 34.78 % | 0.98% | 20.96% | 52.87% | 38.35% | 44.14 % | 35.81 % | 106.53 % | 180.03 % | |
| RMSPE | 55.37 % | 45.21 % | 0.98% | 23.16% | 55.48% | 47.08% | 54.04 % | 46.03 % | 112.82 % | 267.32 % | |
| INTERVAL SATU STANDAR DEVIASI | | | | | | | | | | | |
| | ARIMA | | SARIMA | | PROPHET | | SVR | | FFT | | |
| parameter terbaik | (3, 2, 2) | (0, 1, 2) | (3,2,2)(0,0,0)[4] | (3,1,1)(1,2,3)[4] | <i>weekly_seasonality</i> =False | | kernel <i>sigmoid</i> dan <i>rbf</i> | | | | |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | |
| MAPE | 13.86 % | 27.89 % | 0.70% | 3.17% | 20.53% | 28.50% | 14.52 % | 31.37 % | 88.81 % | 52.45 % | |
| RMSPE | 18.57 % | 34.44 % | 0.70% | 3.77% | 28.91% | 32.53% | 19.54 % | 39.10 % | 104.39 % | 58.39 % | |
| Perbandingan Kinerja UMKM | | | | | | | | | | | |
| DATA ASLI | | | | | | | | | | | |
| | ARIMA | | SARIMA | | PROPHET | | SVR | | FFT | | |
| parameter terbaik | (1, 1, 0) | (2, 0, 0) | (3,3,0)(2,1,3)[4] | (0,0,2)(0,2,0)[4] | <i>weekly_seasonality</i> =False | <i>weekly_seasonality</i> =True | kernel= <i>rbf</i> | | | | |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | |
| MAPE | 13.86 % | 27.89 % | 1.11% | 16.83% | 24.05% | 19.09% | 51.62 % | 45.94 % | 10.79 % | 25.89 % | |
| RMSPE | 18.57 % | 34.44 % | 1.11% | 17.72% | 24.32% | 25.47% | 52.94 % | 48.07 % | 12.25 % | 34.50 % | |

INTERVAL SATU STANDAR DEVIASI

| | ARIMA | | SARIMA | | PROPHET | | SVR | | FFT | |
|-------------------|-----------|---------|-------------------|-------------------|---------------------------|--------|------------|--------|--------|--------|
| parameter terbaik | (2, 3, 2) | (3,3,3) | (0,1,2)(2,1,0)[4] | (2,3,2)(2,0,1)[4] | weekly_seasonality =False | | kernel=rbf | | | |
| | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week | 2 Week | 3 Week |
| MAPE | 6.35% | 8.24% | 0.74% | 6.02% | 8.86% | 17.79% | 38.66% | 41.03% | 8.49% | 20.50% |
| RMSPE | 6.43% | 9.38% | 0.89% | 6.17% | 11.83% | 19.30% | 39.06% | 41.38% | 11.25% | 21.73% |

Pada data asli untuk toko ritel modern, ARIMA menunjukkan kinerja yang kurang baik pada interval 2 minggu dengan MAPE sebesar 52.09% dan RMSPE sebesar 55.37%. Namun, mengalami peningkatan performa pada periode 3 minggu dengan nilai MAPE sebesar 34.78% dan RMSPE 45.21%. Algoritma SARIMA menunjukkan hasil yang konsisten dan terbaik, baik pada interval 2 minggu dengan performa MAPE 0.98% dan RMSPE 0.98% maupun 3 minggu dengan MAPE 20.96% dan RMSPE 23.16%. Sementara itu, prophet memiliki kinerja yang lebih bervariasi, dengan hasil terbaik pada interval 2 minggu dengan MAPE 52.87% dan RMSPE 55.48% serta pada interval 3 minggu dengan MAPE 38.35% dan RMSPE 47.08%, yang menunjukkan bahwa algoritma ini sensitif terhadap parameter *weekly_seasonality*. SVR menunjukkan hasil yang cukup baik pada interval 2 minggu dengan MAPE 44.14% dan RMSPE 54.04% dengan 3 minggu dengan MAPE 35.81% dan RMSPE 46.03%. FFT menunjukkan hasil dengan performa rendah pada interval 2 minggu dengan MAPE 106.53% dan RMSPE 112.82%, disusul pada interval 3 minggu dengan MAPE 180.03% dan RMSPE 267.32%.

Untuk toko ritel modern dengan modifikasi interval satu standar deviasi. ARIMA menunjukkan MAPE sebesar 13.86% dan RMSPE sebesar 18.57% untuk periode 2 minggu, serta MAPE sebesar 27.89% dan RMSPE sebesar 34.44% untuk periode 3 minggu. SARIMA memiliki kinerja yang jauh lebih baik dengan MAPE sebesar 0.70% dan RMSPE sebesar 0.70% untuk periode 2 minggu, serta MAPE sebesar 3.17% dan RMSPE sebesar 3.77% untuk periode 3 minggu. prophet menghasilkan MAPE sebesar 20.53% dan RMSPE sebesar 28.91% untuk periode 2 minggu, serta MAPE sebesar 28.50% dan RMSPE sebesar 32.53% untuk periode 3 minggu. SVR menunjukkan MAPE sebesar 28.50% dan RMSPE sebesar 31.37% untuk periode 2 minggu, serta MAPE sebesar 14.52% dan RMSPE sebesar 19.54% untuk periode 3 minggu. FFT menunjukkan kinerja yang paling buruk dengan MAPE sebesar 88.81% dan RMSPE sebesar 104.39% untuk periode 2 minggu, serta MAPE sebesar 52.45% dan RMSPE sebesar 58.39% untuk periode 3 minggu. Secara keseluruhan, SARIMA menunjukkan kinerja terbaik di antara semua model yang diuji untuk data yang dimodifikasi dengan interval satu standar deviasi maupun dengan memakai data yang asli, dengan nilai MAPE dan RMSPE yang paling rendah. Model ini memberikan prediksi yang lebih akurat dibandingkan dengan model lainnya dalam peramalan untuk toko ritel modern.

Untuk data asli toko UMKM model ARIMA memberikan MAPE sebesar 13.86% dan RMSPE sebesar 18.57% pada interval 2 minggu, serta MAPE sebesar 27.89% dan RMSPE sebesar 34.44% pada interval 3 minggu. Model SARIMA memberikan MAPE sebesar 1.11% dan RMSPE sebesar 1.11% pada interval 2 minggu, serta MAPE sebesar 16.83% dan RMSPE sebesar 17.72% pada interval 3 minggu. Model prophet memberikan MAPE sebesar 24.05% dan RMSPE sebesar 24.32% pada interval 2 minggu, serta MAPE sebesar 19.09% dan RMSPE sebesar 25.47% pada interval 3 minggu. Model SVR memberikan MAPE sebesar 51.62% dan RMSPE sebesar 52.94% pada interval 2 minggu, serta MAPE sebesar 45.94% dan RMSPE sebesar 48.07% pada interval 3 minggu. Model FFT memberikan MAPE sebesar 10.79% dan RMSPE sebesar 12.25% pada interval 2 minggu, serta MAPE sebesar 25.89% dan RMSPE sebesar 34.50% pada interval 3 minggu. Hasil ini menunjukkan bahwa SARIMA dengan data asli memiliki performa yang sangat baik pada interval 2 minggu dan interval 3 minggu.

Untuk data interval satu standar deviasi, model ARIMA memberikan MAPE sebesar 6.35% dan RMSPE sebesar 6.43% pada interval 2 minggu, serta MAPE sebesar 8.24% dan RMSPE sebesar 9.38% pada interval 3 minggu. Model SARIMA memberikan MAPE sebesar 0.74% dan RMSPE sebesar 0.89% pada interval 2 minggu, serta MAPE sebesar 6.02% dan RMSPE sebesar 6.17% pada interval 3 minggu. Model prophet memberikan MAPE sebesar 8.86% dan RMSPE sebesar 11.83% pada interval 2 minggu, serta MAPE sebesar 17.79% dan RMSPE sebesar 19.30% pada interval 3 minggu. Model SVR memberikan MAPE sebesar 38.66% dan RMSPE sebesar 39.06% pada interval 2 minggu, serta MAPE sebesar 41.03% dan RMSPE sebesar 41.38% pada interval 3 minggu. Model FFT memberikan MAPE sebesar 8.49% dan RMSPE sebesar 11.25% pada interval 2 minggu, serta MAPE sebesar 20.50% dan RMSPE sebesar 21.73% pada interval 3 minggu. Data interval satu standar deviasi menunjukkan bahwa semua model mengalami peningkatan akurasi yang signifikan dibandingkan dengan data asli, terutama pada SARIMA dan ARIMA.

Secara keseluruhan, analisis menunjukkan bahwa normalisasi data dengan interval satu standar deviasi dapat secara signifikan meningkatkan kinerja model prediksi. Model SARIMA menunjukkan kinerja terbaik baik pada data asli maupun data yang dimodifikasi dengan interval satu standar deviasi, menghasilkan nilai MAPE dan RMSPE yang paling rendah. Hal ini menunjukkan bahwa SARIMA mampu menangkap pola musiman dan trend dengan sangat baik. Pemodelan musiman SARIMA dirancang khusus untuk menangani data dengan komponen musiman, menjadikannya lebih efektif dalam menangkap pola musiman dibandingkan model lain seperti ARIMA atau SVR. Selain itu, proses *grid search* pada SARIMA membantu menemukan kombinasi parameter yang optimal, meminimalkan kesalahan prediksi. Fleksibilitas model SARIMA, yang menggabungkan bagian *autoregressive*, *differencing*, dan *moving average* dengan komponen musiman tambahan (S), memungkinkan penyesuaian terhadap data dengan pola kompleks. Dengan menggunakan interval satu standar deviasi, model-model prediktif dapat mengurangi bias dan variabilitas yang mungkin ada dalam data asli, sehingga menghasilkan prediksi yang lebih akurat dan andal. Dengan demikian, penggunaan interval satu standar deviasi sebagai metode normalisasi data dapat menjadi salah satu opsi strategi yang sangat efektif dalam meningkatkan akurasi model prediktif. Ini sangat relevan untuk diaplikasikan dalam toko ritel modern dan UMKM di mana prediksi yang akurat sangat penting untuk pengambilan keputusan bisnis yang lebih baik terutama untuk manajemen persediaan stok barang.

IV. SIMPULAN

Dari Hasil yang telah didapat, didapatkan kesimpulan bahwa Algoritma SARIMA menunjukkan kinerja terbaik dalam mengembangkan model prediksi persediaan barang baik pada UMKM maupun toko ritel modern. Algoritma ini mampu mengakomodasi pola musiman dan trend dalam data dan pola stasioner dengan menghilangkan data *outlier*, memberikan hasil prediksi yang lebih andal berdasarkan perhitungan MAPE dan RMSPE dibandingkan dengan algoritma *machine learning* lainnya. Selain itu Berdasarkan hasil penelitian, data yang diproses dengan metode modifikasi interval satu standar deviasi menunjukkan perbaikan dalam kualitas data yang digunakan untuk *forecasting*, menghasilkan model prediksi yang lebih akurat dibandingkan dengan data asli tanpa modifikasi *outlier* walau pada dasarnya normalisasi data dengan menghilangkan *outlier* dalam *forecasting* tidak terlalu dianjurkan namun dapat menjadi salah satu opsi. Implementasi algoritma *machine learning*, khususnya SARIMA sebagai Algoritma paling akurat, membantu UMKM dan toko ritel modern dalam mengantisipasi permintaan konsumen secara lebih akurat, yang berkontribusi pada optimasi manajemen persediaan, mengurangi risiko kelebihan stok atau kekurangan stok, dan meningkatkan efisiensi operasional. Untuk penelitian selanjutnya, disarankan eksplorasi teknik algoritma *machine learning* lain seperti *exponential smoothing*, regresi linear, dan *neural networks* untuk prediksi persediaan barang. Pengumpulan data dengan rentang waktu lebih panjang dibutuhkan untuk meningkatkan akurasi model, serta memastikan keseimbangan data antara UMKM dan toko ritel modern untuk pemahaman yang lebih mendalam terhadap dinamika persaingan penjualan dan persediaan barang

UCAPAN TERIMA KASIH

Puji syukur yang sedalam-dalamnya dipanjatkan ke hadirat Tuhan Yang Maha Esa atas berkat dan rahmat-Nya, sehingga dapat terselesainya penelitian ini dengan baik dan tepat waktu. Terima kasih yang sebesar-besarnya kepada semua pihak yang telah memberikan arahan, dukungan, dan bimbingan selama proses penelitian dan penulisan makalah jurnal.

DAFTAR PUSTAKA

- [1] A. Prasetya, "Kementrian Keuangan," Kementrian Keuangan, 2023. [Online]. Available: <https://www.djkn.kemenkeu.go.id/kpknl-medan/baca-artikel/15879/Mengenal-Program-Pembinaan-UMKM-Kemenkeu-Satu-Tahun-2023.html#:~:text=Pengertian%20UMKM&text=Sesuai%20dengan%20Peraturan%20Pemerintah%20Nomor,diatur%20dalam%20Peraturan%20Pemerintah%20ini>. [Accessed 23 2 2024].
- [2] H. Hassyddiqy and Hasdiana, "Analisis Peramalan (Forecasting) Penjualan Dengan Metode ARIMA (Autoregressive Integrated Moving Average) Pada Huebee Indonesia," *Jurnal Data Science*, vol. 2, no. 2, pp. 92-100, 2023.
- [3] N. R. W. T. Handayani, M. Maslim and P. Mudjihartono, "Forecasting of Catfish Sales by Time Series Using the SARIMA method," *Jurnal Buana Informatika*, vol. 11, no. 2, pp. 94-93, 2020.
- [4] Suseno and S. Wibowo, "Penerapan Metode ARIMA dan SARIMA Pada Peralaman Penjualan Telur Ayam Pada PT Agromix Lestari Group," *Jurnal Teknologi dan Manajemen Industri Terapan*, vol. 2, no. 1, pp. 33-40, 2023.
- [5] F. D. P. Sari and L. Tanti, "Metode ARIMA Dalam Prediksi Penjualan Karton Pada PT. Industri Pembungkus International ARIMA Method in Predicting Carton Sales at PT. International Packaging Industry," *Jurnal JUREKSI (Jurnal Rekayasa Sistem)*, vol. 2, no. 1, pp. 220-232, 2024.
- [6] 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, pp. 278-287, 2020.
- [7] B. Jange, "Prediksi Harga Saham Bank BCA Menggunakan Prophet," *Journal of Trends Economics and Accounting Research*, vol. 2, no. 1, pp. 1-5, 2021.
- [8] Zaeniah, Zaenudin and B. Imran, "Implementation of Support Vector Regression In The Prediction Of The Number Of Tourist Visits To The Province West Nusa Tenggara (Ntb)," *Journal of Computing and Information System*, vol. 18, no. 2, pp. 117-122, 2022.

- [9] A. Fumi, A. Pepe, L. Scarabotti and M. M. Schiraldi, "Fourier analysis for demand forecasting in a fashion company," *International Journal of Engineering Business Management*, vol. 5, pp. 1-10, 2013.
- [10] D. Susilokarti, S. S. Arif, S. Susanto and L. Sutiarto, "Studi Komparasi Prediksi Curah Hujan Metode Fast Fourier Transformation (Fft), Autoregressive Integrated Moving Average (Arima) Dan Artificial Neural Network (Ann)," *Jurnal Agritech*, vol. 35, no. 2, pp. 241-247, 2015.
- [11] L. E. D. K. Sari, A. Widjaja and S. L. Liliawati, "Analisis Deret Waktu dari Produk yang Terjual Menggunakan Beberapa Teknik Populer," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 9, no. 1, pp. 110-126, 2023.
- [12] 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, 2023.
- [13] V. P. Ariyanti and T. Yusnitasari, "Comparison of ARIMA and SARIMA for Forecasting Crude Oil Prices," *Jurnal Rekayasa Sistem dan Teknologi Informasi*, vol. 7, no. 2, pp. 405-413, 2023.
- [14] A. Mauludiyanto, G. Hendranto, P. M. Hery and Suhartono, "Pemodelan ARIMA dan Deteksi Outlier Data Curah Hujan Sebagai Evaluasi Sistem Radio Gelombang Milimeter," *Jurnal Ilmiah Teknologi Informasi*, vol. 7, no. 3, pp. 107-112, 2009.
- [15] S. Afrida, "Medium," 2021. [Online]. Available: <https://yandaafrida.medium.com/association-rule-market-basket-analysis-menggunakan-python-a9c49b4bfc69#:~:text=Yang%20dimaksud%20dengan%20association%20rules,maupun%20online%20yang%20kita%20miliki..> [Accessed 2024 12 12].