

Forecasting Spare Part pada Commercial Vehicle PT XYZ dengan Klasifikasi ADI-CV

MUHAMMAD IRFAN RIZKI¹, YENNY MAYA DORA², WAHIDIYAT SUYUDI³,
YANTHY MARDIANA⁴

^{1, 3, 4} Program Magister Manajemen Sekolah Pascasarjana Universitas Widyatama, Indonesia

² Dosen Fakultas Bisnis dan Manajemen Universitas Widyatama, Indonesia

e-mail: irfan.rizki@widyatama.ac.id

ABSTRAK

After Sales memiliki kontribusi positif pada pertumbuhan profit permintaan *spare part* suatu perusahaan. PT. XYZ merupakan agen tunggal pemegang merek mobil kendaraan niaga di Indonesia dengan visi menjadi *market share* terbesar secara global dipasar internasional. Peranan penting yang dilakukan PT. XYZ dalam upaya memenuhi seluruh kebutuhan permintaan domestik atau ekspor dengan langkah menerapkan rencana inventaris yang mencakup peramalan kebutuhan suku cadang setiap bulan. Pada kondisi saat ini metode yang digunakan oleh perusahaan hanya menggunakan metode peramalan dengan rata-rata 6 bulan terakhir atau *Moving Average* yang digunakan untuk menyiapkan seluruh suku cadang PT. XYZ. Metode ini dinilai kurang efektif karena ketika terjadinya bentuk permintaan *spare part* yang memiliki tingkat variasi tinggi maka penyimpangan pada hasil peramalan menyebabkan *back order* terhadap pelanggan dan *loss sales* yang dapat mempengaruhi nilai suatu perusahaan yaitu *fast and easy process*. Berdasarkan permasalahan tersebut, maka PT. XYZ membutuhkan perbaikan terhadap mekanisme peramalan *spare part*-nya. Tujuan dari dilakukan penelitian yaitu menghasilkan metode klasifikasi *spare part* berdasarkan bentuk permintaannya dan memutuskan metode peramalan yang paling tepat untuk masing-masing kelompok *spare part* dengan langkah membandingkan enam metode peramalan yaitu metode *Croston Optimized*, *TSB*, *SESOpt*, *ADIDA*, *IMAPA*, *Moving Average*. Semua metode peramalan akan dibandingkan atas dasar parameter nilai *forecasting error*. Pada hasil yang didapat menunjukkan metode *Croston Optimized* memiliki hasil yang lebih baik dari metode *moving average* dengan memperbaiki kesalahan sebesar 7%.

Kata Kunci: *After Sales, Forecasting, Spare Part.*

ABSTRACT

After Sales has a positive contribution to the profit growth of a company's *spare part* demand. PT XYZ is the sole agent of commercial vehicle car brand holders in Indonesia with a vision to become the largest market share globally in the international market. An important role played by PT XYZ in an effort to meet all domestic or export demand needs by implementing an inventory plan that includes forecasting the need for spare parts on a monthly basis. In the current condition, the method used by the company only uses a forecasting method with the average of the last 6 months or *Moving Average* which is used to prepare all spare parts of PT. XYZ. This method is considered less effective because when there is a form of spare part demand that has a high level of variation, deviations in forecasting results cause back orders to customers and loss of sales which can affect the value of a company, namely *fast and easy process*. Based on these problems, PT XYZ needs improvements to its *spare part* forecasting mechanism. The purpose of the research is to produce a spare part classification method based on the form of demand and decide the most appropriate forecasting method for each spare part group by comparing six forecasting methods, namely the *Croston Optimized* method, *TSB*, *SESOpt*, *ADIDA*, *IMAPA*, *Moving Average*. All forecasting methods will be compared on the basis of the forecasting error value parameter. The results obtained show that the *Croston Optimized* method has better results than the *moving average* method by correcting an error of 7%.

Keywords: *After Sales, Forecasting, Spare Part.*

1. PENDAHULUAN

Kebutuhan kendaraan dari tahun ke tahun khususnya mobil di Indonesia mengalami peningkatan, Dari tahun 2012-2022 pengguna jumlah mobil penumpang di Indonesia sudah meningkat sebesar 6,74 juta unit atau bertumbuh sekitar 65%. Hal ini dikarenakan Indonesia adalah negara yang sedang berkembang dan terus meningkatkan pembangunan khususnya dalam fasilitas transportasi. Kategori kendaraan yang mayoritas diminati terutama untuk menunjang proses bisnis masyarakat yaitu kategori kendaraan niaga yang bisa dipakai untuk menunjang keperluan pribadi seseorang (Mardianto, 2021). Dengan meningkatnya permintaan kendaraan niaga mengakibatkan tingginya kebutuhan *spare part* akan kendaraan tersebut, layanan ketersediaan *spare part* ini perlu diperhatikan karena mempengaruhi tingkat kepercayaan pelanggan terhadap brand dan keputusan pelanggan dalam membeli mobil khususnya kendaraan niaga (Ramadhan, 2021). Oleh karena itu, konsep *supply chain management* khususnya dalam *inventory management spare part* menjadi landasan dasar bagi perusahaan untuk terus berkompetitif.

Mobil kategori *commercial vehicle* adalah jenis kendaraan yang sering digunakan dalam kegiatan angkut mengangkut, baik mengangkut manusia ataupun kebutuhan logistik. *commercial vehicle* memiliki part bervariasi lebih dari 15.000 part dan pada umumnya part tersebut dalam kondisi tertentu akan rusak sehingga diperlukan pengganti yang sama dengan jumlah dan kualitas yang sesuai dan juga cepat (Budiningsih & Jauhari, 2017). Berbagai macam *part*, tingginya tingkat fluktuasi permintaan dipasaran yang disebabkan oleh variasi faktor pemakaian dan kebutuhan ketersediaan di pasar, membuat *spare part* kendaraan menjadi permasalahan yang unik. Salah satu langkah *improvement* dari *spare part management* adalah dengan mengetahui berapa permintaan pelanggan dengan metode forecasting yang sesuai (Jiang, et al., 2017).

Peramalan permintaan berfungsi untuk memelihara tersedianya *stock* dan membuat perencanaan untuk suatu proses produksi secara bersama-sama dengan supplier, dengan melakukan peramalan maka dari segi supplier lebih siap dalam menyiapkan materialnya untuk menunjang tingkat ketersediaan *spare part*. Jika semakin presisi dan cepat peramalan permintaan *spare part* yang diperoleh, maka akan cepat juga proses *lead time* dan pemenuhan order customer, sehingga dapat meringankan biaya operasional yang berkaitan dengan penanganan *spare part*, seperti *rework*, space gudang, dan logistik (Klug, 2018).

Rendahnya keakuratan hasil prediksi suku cadang dapat berdampak pada permasalahan lain yang dihadapi perusahaan, seperti kapasitas penyimpanan terbatas. Semua data permintaan pelanggan perusahaan berisi beberapa jenis data deret waktu dengan pola dan komponen yang berbeda, yaitu tren, siklus, musiman, dan keacakan yang berbeda. Apalagi bentuk permintaan pelanggan terhadap suku cadang, khususnya kendaraan niaga, berfluktuasi secara signifikan dari periode ke periode bahkan mungkin nol di beberapa periode sehingga memerlukan persiapan lebih lanjut (Altay & Litteral, 2011).

Permintaan dari pelanggan tidak selalu terjadi disetiap bulan sehingga mengakibatkan pola data tidak beraturan. Produk seperti suku cadang mempunyai karakteristik data yang lebih kompleks dibandingkan jenis produk lainnya dikarenakan pola yang diminta tidak teratur. Permintaan *intermiten* adalah permintaan yang mempunyai nilai nol atau bukan nol. Dengan kata lain, nilai nol berarti tidak ada permintaan dari pelanggan, dan nilai selain nol berarti ada permintaan. Permintaan suku cadang sulit diperamalan karena waktu permintaan yang tidak teratur. Oleh karena itu, perlu dilakukan klasifikasi pola permintaan suku cadang (Simamora, 2019).

Belum ada mekanisme untuk mengklasifikasikan karakteristik permintaan suku cadang. Hal inilah yang menjadi salah satu penyebab tidak ditemukannya metode peramalan yang tepat dan tidak tercapainya keakuratan yang optimal dalam menangani permintaan suku cadang di PT. XYZ, klasifikasi *spare part* memudahkan tugas operasional, terutama bagi manajer saat mengumpulkan sampel yang "berharga", namun juga membantu dalam pengambilan keputusan. Oleh karena itu, kami menggunakan metode peramalan sederhana yaitu rata-rata permintaan atau *moving average* (MA) enam bulan terakhir untuk meramalkan permintaan bulanan seluruh suku cadang PT. XYZ. Jika semua part menggunakan *moving average* maka hasil peramalan parameter sensitif terhadap nilai *outlier*, yang membuat metode *moving average* tidak cocok untuk permintaan *spare part* yang memiliki nilai variasi yang tinggi. Akibatnya, kebanyakan hasil peramalannya memiliki akurasi yang belum optimal. Berdasarkan permasalahan tersebut maka sebagai evaluasi jenis permintaan material akan dipergunakan dua parameter yaitu ADI (*Average Inter-Demand Interval*) adalah rata-rata interval antara dua permintaan *spare part* dan CV

(Coefficient of Variation). Kaya et al., (2020) membuat batasan karakteristik mengenai jenis permintaan Model ADI meliputi: *Intermittent*, *Erratic*, *slow moving* dan *lumpy*. Penelitian ini menggunakan data dari PT. XYZ yang bergerak dalam bisnis *commercial vehicle* salah satu agen tunggal pemegang merek di Indonesia yang berkantor pusat di Jakarta Utara. Data yang digunakan adalah data *demand* dan *stock keeping unit* (SKU) dari tahun 2022-2023. Sehingga, penelitian ini menggunakan analisis *Average Demand Interval* (ADI). Setelah melakukan klasifikasi model, selanjutnya akan dilakukan forecasting untuk setiap klasifikasi yang telah didapat.

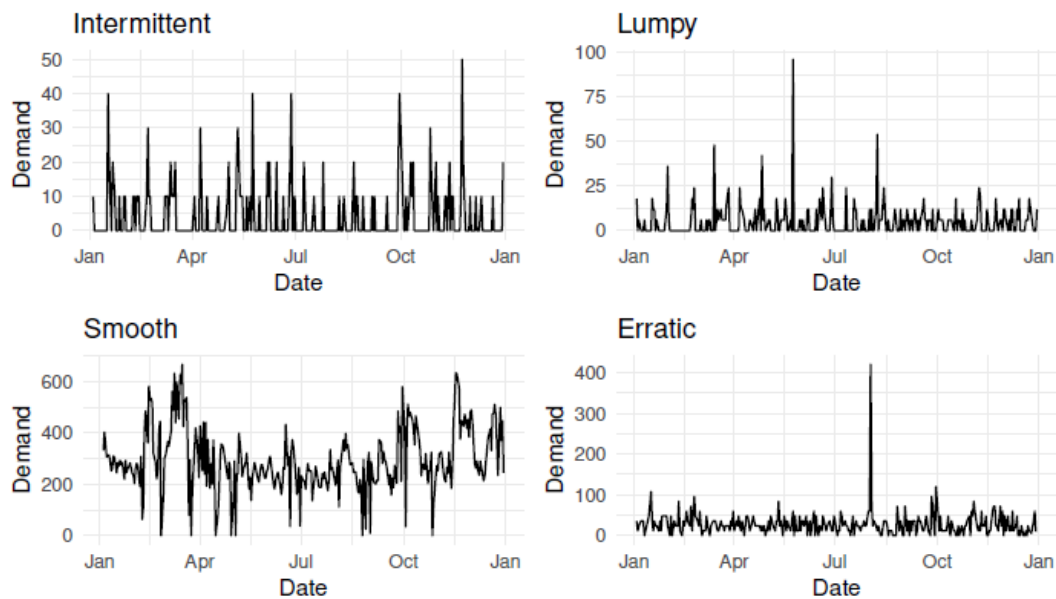
2. METODE PENELITIAN

Data pada penelitian ini menggunakan data pada perusahaan PT. XYZ yang bergerak dalam bisnis *commercial vehicle*, salah satu agen tunggal pemegang merek di Indonesia. Data terdiri dari 16000 *stock keeping unit* pada periode tahun 2021 s.d 2023. Pengolahan data dilakukan menggunakan software *python*. Berikut ini data yang digunakan:

Tabel 1. Variabel Penelitian

No	Stock keeping Unit	Description	01-01-2021	:	01-12-2023
1.	IX-***** 514-X	Oil Filter	10634	:	19698
2.	IY-***** 328-X	Gasket Cyl	1765	:	920
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
:	:	:	:	:	:
16000	IZ-***** 111-X	Fan Belt	101	:	780

Metode klasifikasi yang sesuai dibutuhkan untuk mengetahui bagaimana klasifikasi pola data SKU. Sehingga akan digunakan metode *Average Demand Interval* (ADI) dan *Coefficient of Variation* (CV) untuk klasifikasi dan dilanjutkan dengan meramalkan kebutuhan *stock keeping unit* untuk 3 sampai 6 bulan kedepan. ADI-CV adalah analisa yang digunakan dalam menentukan jenis pengendalian part berdasarkan karakteristik pola pergerakan permintaan masing-masing *stock keeping unit*. Berikut ini merupakan klasifikasi pola permintaan pada ADI-CV (Putri, 2022).



Gambar 1. Klasifikasi Pola Permintaan

Penjelasan pola permintaan pada gambar 1 sebagai berikut (Spiliotis, 2022):

- Intermittent*
Permintaan customer memiliki ciri yaitu memiliki variasi secara signifikan dari waktu ke waktu, dan seringkali terjadi dengan sporadis atau pola permintaan yang tidak teratur.
- Lumpy*
Permintaan pelanggan yang ada dalam skala besar ketika waktu-waktu tertentu, akan tetapi kemudian dapat berubah menjadi tidak teratur atau tidak ada permintaan.
- Smooth*
Permintaan pola pelanggan ini yaitu relatif stabil dan dapat diperamalan dengan baik sepanjang waktu.
- Erratic*
Permintaan pola klasifikasi pelanggan yang tidak dapat diperamalan dengan baik dan seringkali memiliki variasi secara acak tanpa pola yang jelas.

Adapun rumus *Average Demand Interval* (ADI) dan *Coefficient of Variation* (CV) sebagai berikut (Putri, 2022):

$$ADI = \sum_{i=1}^N t_i \quad \dots (1)$$

$$CV = \frac{\sqrt{\frac{\sum_{i=1}^M (\varepsilon_i - \varepsilon)^2}{N}}}{\varepsilon} \quad \dots (2)$$

dengan,

t_i adalah interval antara dua permintaan yang berurutan

N adalah jumlah Periode Permintaan *non-zero*

M adalah jumlah Periode

ε adalah rata-rata

ε_i adalah permintaan *spare part* (unit ke -i)

Berdasarkan klasifikasi data permintaan pada gambar 1, analisis nilai ADI-CV dapat dibagi menjadi:

- Suatu nilai $ADI < 1,32$ dan Nilai $CV^2 \geq 0,49$ maka pola permintaannya adalah *erratic*
- Suatu nilai $ADI < 1,32$ dan Nilai $CV^2 > 0,49$ maka pola permintaannya adalah *Smooth*
- Suatu nilai $ADI \geq 1,32$ dan Nilai $CV^2 \geq 0,49$ maka pola permintaannya adalah *Lumpy*
- Suatu nilai $ADI \geq 1,32$ dan Nilai $CV^2 < 0,49$ maka permintaannya adalah *Intermittent*

3. HASIL DAN PEMBAHASAN


Penelitian ini menggunakan data *stock keeping unit* dari tahun 2021 s.d 2023 pada kasus *spare part* di PT. XYZ manufaktur Indonesia. Sebelum melakukan pemodelan menggunakan *Avarage Demand Interval (ADI)* dan *Coefficient of Variation (CV)*, tahapan awal dalam penelitian ini adalah melakukan analisis deskriptif dalam upaya mengetahui gambaran karakteristik pada data. Karakteristik *spare part* disajikan dalam Tabel 2 berikut:

Tabel 2. Statistika Deskriptif *Stock Keeping Unit*

No	SKU	Description	Max	Min	Rata-rata
1.	IX-***** 514-X	Oil Filter	24214	13031	19369
2.	IY-***** 328-X	Gasket Cyl	2502	202	1234
⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮
16000	IZ-***** 111-X	Fan Belt	953	567	232

Sumber: Diolah Menggunakan Python

Apabila dilihat secara visual maka dapat diperoleh hasil sebagai berikut:



Gambar 2. Pola Permintaan

Pada Gambar 2 menunjukkan bahwa pola *demand spare part* yang memiliki karakteristik berbeda-beda dari segi *stock keeping unit (SKU)* sehingga perlu metode yang sesuai untuk masing-masing SKU. Selanjutnya 16.000 *spare part* akan digunakan untuk membuat klasifikasi *spare part* berdasarkan pola permintaan dengan menggunakan software *python*. Hasil klasifikasi adalah sebagai berikut:

Tabel 3. *Category* Berdasarkan Permintaan Demand

Kategori	Amount (Bio)	Persentase Demand (%)
Smooth	410.324	42.6 %
Intermittent	221.120	23.0 %

Kategori	Amount (Bio)	Persentase Demand (%)
<i>Eratic</i>	111.671	11.6 %
<i>Lumpy</i>	98.324	10.2 %
<i>Non- Moving</i>	121.341	12.6 %

Sumber: Diolah Menggunakan Python

Berdasarkan Tabel 3, diketahui *category Smooth* memiliki permintaan *demand* yang terbesar artinya *category Smooth* berkontribusi sebesar 42.6 % terhadap *demand* penjualan. Selanjutnya dengan *tools python* didapatkan nilai ADI terbesar yaitu 22,3 dan nilai ADI terkecil yaitu 0,93. *Script python* untuk melakukan klasifikasi *spare part* adalah sebagai berikut:

```

result = pd.DataFrame()
testing = pd.DataFrame()
for x in df['unique_id'].unique().tolist():
    print(f"=====SKU {x}=====")
    temp = df[df["unique_id"]==x].copy()
    train = temp[temp['ds']<"2023-08-01"]
    test = temp[temp['ds']>="2023-08-01"]
    model = [TSB(0.5,0.5),SESOpt(),ADIDA(),IMAPA(),CrostonOptimized(),HistoricAverage()]
    sf = StatsForecast(
        df = train,
        models = model,
        freq = "MS"
    ) sf.fit(train)
    df_cv = sf.cross_validation(
        df=train,
        h=1,
        step_size=1,
        n_windows=18
    )
    df_cv = df_cv[['ds','y',"TSB","SESOpt","ADIDA","CrostonOptimized","HistoricAverage","akurasi
    TSB","akurasi SESOpt","akurasi ADIDA","akurasi Crosston","akurasi HistoricAverage']]
    result = pd.concat([result,df_cv])
    result_testing =
    sf.predict(h=1).reset_index().merge(test,left_on=["unique_id","ds"],right_on=["unique_id","ds"])
    testing = pd.concat([testing,result_testing])
    testing["akurasi TSB"] = np.where(
    testing['y']>=testing['TSB'],testing["TSB"]/testing['y'],testing["y"]/testing['TSB'])
    testing["akurasi SESOpt"] = np.where(
        testing['y']>=testing['SESOpt'],testing["SESOpt"]/testing['y'],testing["y"]/testing['SESOpt'])
    testing["akurasi ADIDA"] = np.where(
        testing['y']>=testing['ADIDA'],testing["ADIDA"]/testing['y'],testing["y"]/testing['ADIDA'])
    testing["akurasi Crosston"] = np.where(
    testing['y']>=testing['CrostonOptimized'],testing["CrostonOptimized"]/testing['y'],testing["y"]/testin
    g['CrostonOptimized'] )
    testing["akurasi HistoricAverage"] = np.where(
    testing['y']>=testing['HistoricAverage'],testing["HistoricAverage"]/testing['y'],testing["y"]/testing['H
    isticAverage'])
    prediction=sf.predict(h=5)
    df_prediction=pd.concat([df_prediction, prediction])

```

Tabel 4. Hasil Klasifikasi *Spart Parts*

Kategori	Line Spart Parts	Persentase Line (%)	Accuracy ADI (%)
<i>Smooth</i>	2512	15,7 %	75.1 %
<i>Intermittent</i>	6123	38,3 %	61.3 %
<i>Eratic</i>	1532	9,6 %	62.2 %
<i>Lumpy</i>	2890	18.1 %	51.6 %
<i>Non- Moving</i>	2943	18.4 %	53.4 %

Sumber: Diolah menggunakan *Python*

Berdasarkan Tabel 4 diperoleh pola klasifikasi *demand* terbesar berada pada kategori *intermittent* artinya permintaan pelanggan memiliki ciri yaitu bervariasi secara signifikan dari waktu ke waktu, dan seringkali terjadi dengan *sporadis* atau pola permintaan yang tidak teratur. Hal tersebut tentunya membuat *demand* permintaan menjadi bervariasi. Selain itu *accuracy* secara kategori pada *intermittent* masih kurang dari 70%, sehingga langkah selanjutnya adalah melakukan analisa *forecast* untuk 16.000 SKU berdasarkan *category line spare part* dengan metode *TSB (Teunter-Syntetos-Babai)*, *SES (Simple Exponential Smoothing)*, *ADIDA (Adaptive Damped Innovation Diffusion Model)*, *IMPA (Intermittent Multiple Aggregation Prediction Algorithm)*, *CrostonOptimized* dan *Historical Average*.

Tabel 5. Accuracy Rata-rata (%) *Forecast* Berdasarkan Metode

Metode	Accuracy Rata-rata (%)
<i>TSB (Teunter-Syntetos-Babai)</i>	55.2 %
<i>SES (Simple Exponential Smoothing)</i>	60.1 %
<i>ADIDA (Adaptive Damped Innovation Diffusion Model)</i>	59.4 %
<i>IMPA (Intermittent Multiple Aggregation Prediction Algorithm)</i>	64.1 %
<i>Croston Optimized</i>	65.2 %
<i>Historical Average</i>	58.2 %

Sumber: Diolah menggunakan *Python*

Berdasarkan Tabel 5 didapatkan nilai *accuracy forecast* tertinggi yaitu dengan metode *Croston Optimized*. Metode ini dapat meningkatkan akurasi dengan mengoptimalkan parameter model, seperti faktor pemulusan untuk permintaan dan interval waktu antara permintaan. Perbaikan bisa dalam bentuk penyesuaian otomatis parameter berdasarkan historis kinerja peramalan. Sehingga dalam hal ini terjadi peningkatan sebesar 7% apabila model yang digunakan tidak hanya dengan menggunakan nilai rata-ratanya. Semua model tentunya dilakukan proses *automodel selection* sehingga mendapatkan akurasi yang optimal pada masing-masing *stock keeping unit*.

4. SIMPULAN DAN SARAN

Berdasarkan analisis data yang telah dilakukan, yaitu klasifikasi dengan ADI-CV dan dilanjutkan dengan proses forecasting, dapat disimpulkan bahwa dengan menggunakan klasifikasi ADI-CV maka setiap material dapat diklasifikasikan kedalam bentuk pola *demand*, sehingga akan memudahkan proses analisa selanjutnya apabila dilakukan metode *forecasting*. Ketika dilakukan metode *forecasting* menggunakan beberapa model didapatkan hasil bahwa ketika menggunakan beberapa model selain rata-rata *demand* maka terjadi peningkatan akurasi sebesar 7%. Sehingga dapat mengoptimalkan *stock* pada masing-masing *stock keeping unit* dimana terdapat 16.000

material yang berada di PT. XYZ. Berdasarkan hasil penelitian yang telah diperoleh, diharapkan perusahaan dapat memperhatikan, mengendalikan, mengontrol, dan mempersiapkan *stock* yang optimal sehingga bisa mendukung *core value* perusahaan yaitu *fast dan easy proses*. Sehingga jika pelayanan *spare part* dengan akurasi yang baik maka produk akan lebih optimal tersedia.

DAFTAR PUSTAKA

- Altay, N., & Litteral, L. A. (2011). *Service Parts Management*. Demand Forecasting and Inventory Control, 1st Edition, XIV.
- Budiningsih, E., & Jauhari, W. A. (2017). Analisis Pengendalian Persediaan Spare Part Mesin Produksi di PT. Prima Sejati Sejahtera dengan Metode Continuous Review. *PERFORMA: Media Ilmiah Teknik Industri*, 16(2).
- F. Klug, (2018). *Logistics Management in The Automotive Industry: Basics of Logistics in Automotive Engineering*, 2nd ed. Heidelberg: SpringerVerlag.
- Mardianto, T. (2021). Perhitungan Harga Pokok Produksi Sebagai Dasar Penentuan Harga Jual Pada Perusahaan Karoseri Kuda Terbang Malang. *JEA17: Jurnal Ekonomi Akuntansi*, 6(2), 263-278.
- Jiang, P., Liu, X., Huang, Y., & Yuan, Y. (2017). *An Adaptive Data-Driven Model for Erratic Demand Forecasting*. *IFAC-PapersOnLine*, 50(1), 9020-9025.
- Putri, N. H., Sukarno, I., & Dewabharata, A. (2022). *Inventory Control Analysis of Flowline Pipe* (Case Study: PT. Pertamina Hulu Rokan Field Limau). *Journal of Emerging Supply Chain, Clean Energy, and Process Engineering*, 1(2), 97-106.
- Kaya, G. O., Sahin, M., & Demirel, O. F. (2020). *Intermittent Demand Forecasting: A Guideline for Method Selection*. *Sādhanā*, 45, 1-7.
- Ramadhan, D. I., & Santosa, B. (2021). Analisis Kinerja Peramalan dan Klasifikasi Permintaan Auto Parts Berbasis Data Mining. *Jurnal Teknik ITS*, 9(2), A162-A169.
- Simamora, Y. K., Puspita, E., & Herrhyanto, N. (2019). Peramalan Jumlah Permintaan Spare Part Lcv Bushing Struthbar Dengan Menggunakan Metode Croston Dan Metode Syntetos Boylan Approximation. *Jurnal Eurekamatika*, 7(1), 47-57.
- Spiliotis, E., Makridakis, S., Semenoglou, A. A., & Assimakopoulos, V. (2022). *Comparison of Statistical and Machine Learning Methods for Daily SKU Demand Forecasting*. *Operational Research*, 22(3), 3037-3061.