

Analisis Kinerja Peramalan dan Klasifikasi Permintaan *Auto Parts* Berbasis *Data Mining*

Defa Ihsan Ramadhan, dan Budi Santoso
 Departemen Teknik Sistem dan Industri, Institut Teknologi Sepuluh Nopember (ITS)
e-mail: budi_s@ie.its.ac.id

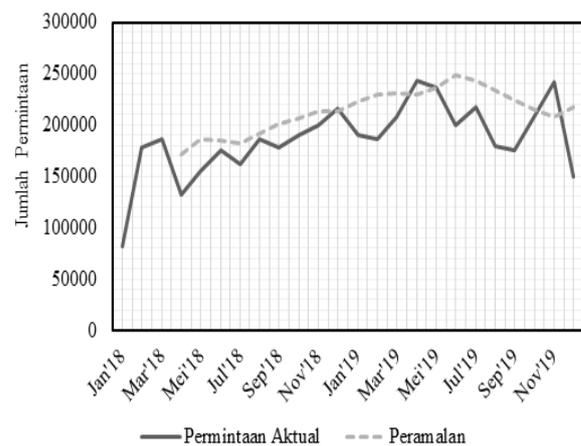
Abstrak—Kontribusi *after sales service* yang besar terhadap profit dan pertumbuhan bisnis menyebabkan *spare part management* menjadi faktor yang penting untuk bersaing di pasar. Termasuk bagi PT. X, produsen mobil penumpang dengan *market share* terbesar secara global di tahun 2019. Berbagai upaya *spare part management* telah dilakukan PT. X untuk memenuhi kebutuhan *part* domestik maupun ekspor. Salah satu upayanya adalah melakukan perencanaan produksi bulanan (*Getsudo*), termasuk peramalan permintaan *spare part* setiap bulannya, akan tetapi, metode peramalan *Moving Average*, yang saat ini digunakan untuk semua *spare part* di PT. X, kurang efektif pada beberapa pola permintaan *spare part* yang variasinya tinggi. Penyimpangan pada hasil peramalan berdampak pada *lead time back order* dan biaya *material handling* yang semakin besar. Berdasarkan hal tersebut, maka PT. X memerlukan perbaikan terhadap sistem peramalan *spare part*-nya. Penelitian ini memiliki dua tujuan utama. Tujuan pertama adalah mengusulkan metode klasifikasi *spare part* berdasarkan pola permintaannya sebelum diramalkan. Tujuan kedua adalah menentukan metode peramalan yang paling sesuai untuk masing-masing kelompok *spare part* dengan cara membandingkan empat metode peramalan, yaitu: Croston, Modifikasi Croston, SVR, dan ANN. Seluruh metode peramalan dibandingkan berdasarkan parameter *forecasting error* dan *robustness*. Hasil penelitian ini menunjukkan bahwa metode SVR memiliki kinerja yang lebih unggul dari metode lainnya di tahap *training* maupun *testing*. Selain itu, ketika diimplementasikan untuk peramalan multi-periode, metode SVR juga lebih unggul dan dapat memperbaiki kesalahan peramalan sebesar 19% dari metode peramalan yang saat ini digunakan oleh PT. X.

Kata Kunci—ANN, Data Mining, K-Medoids, Spare Part Management, SVR.

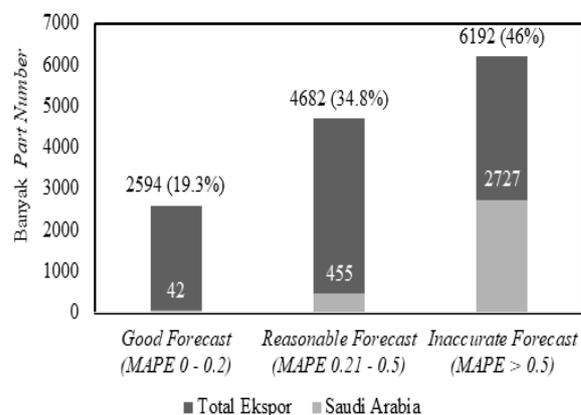
I. PENDAHULUAN

SALAH satu produk otomotif dengan penjualan yang pesat adalah mobil penumpang. Angka kepemilikan mobil penumpang yang terus meningkat menyebabkan pertumbuhan permintaan *spare part* [1]. Kualitas dan ketersediaan *spare part* di pasar menjadi faktor kompetitif yang mempengaruhi kepercayaan *customer* terhadap *brand* dan keputusan *customer* dalam membeli mobil [2]. Oleh karena itu, *spare part management* menjadi aktivitas yang penting bagi perusahaan otomotif.

Suatu mobil modern dapat tersusun lebih dari 30.000 *part*. Suatu waktu, *part* tersebut akan rusak dan *part* pengganti harus tersedia dalam jumlah dan kualitas yang tepat. Banyaknya macam *part*, tingginya ketidakpastian permintaan *part* akibat variasi faktor pemakaian, dan tuntutan ketersediaan di pasar, menyebabkan *spare part management* menjadi kompleks. Salah satu aktivitas penting dari *spare part management* adalah peramalan permintaan [3].



Gambar 1. Peramalan existing yang cenderung melebihi permintaan aktual ekspor spare part di PT. X.



Gambar 2. Kinerja metode peramalan SMA terhadap permintaan spare part di PT. X diukur dengan Mean Absolute Percentage Error (MAPE).

Peramalan permintaan berfungsi sebagai petunjuk bagi produsen untuk menjaga level ketersediaan *spare part* dan melakukan perencanaan produksi bersama dengan *supplier*. Semakin cepat dan akurat peramalan permintaan *spare part* yang dihasilkan, semakin efisien *lead time* pemenuhan *order*, sehingga dapat menurunkan biaya-biaya yang berhubungan dengan penanganan *spare part*, seperti: *rework*, penyimpanan, dan transportasi [2].

Salah satu perusahaan otomotif dengan *market share* terbesar secara global di tahun 2019 adalah PT. X. Dalam mempertahankan *market share*, PT. X sangat memerhatikan kualitas pelayanan *after sales*-nya. Oleh karena itu, *spare part management* adalah aktivitas yang penting bagi PT. X. Peramalan permintaan merupakan bagian dari aktivitas bulanan atau *Getsudo* di PT. X, yang berarti aktivitas yang dilakukan setiap bulan untuk memastikan kesiapan produksi

Tabel 1.
Nilai cut-off ADI dan CV² dari aturan Boylan

	ADI ≤ 1.32	ADI > 1.32
CV ² > 0.9	Erratic	Lumpy
CV ² ≤ 0.9	Smooth	Intermittent

Tabel 2.
Rentang nilai parameter SVR yang digunakan dalam penelitian ini

Parameter	Nilai*
ϵ	[0; 1; 1]
γ	2 ^x x = [0; 10; 0,66]
C	10 ^x x = [-10; -0,1; -0,66]

Tabel 3.
Struktur dan parameter ANN yang digunakan dalam penelitian ini

Parameter	Nilai
Jumlah hidden layer	2
Jumlah neuron	16; 32; 24
Dropout rate	[0,166; 0,500; 0,066]
Regularisasi (λ)	0,0001; 0,001; 0,01
η	0,0001; 0,001; 0,01

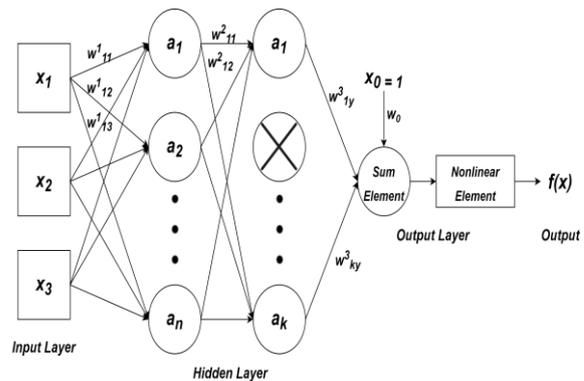
Tabel 4.
Part yang menjadi pusat masing-masing kluster K-Medoids

No. Part	ADI	CV ²	Kluster Ke-
629400D090	1,06	2,12	1
135020C030	1,80	1,92	2
819200K050	1,00	0,96	3
123720Y281	3,00	1,75	4
531210K560	2,00	1,06	5
616060K030	1,25	0,48	6
811700K320	3,80	1,63	7
17750BZ010	1,41	4,44	8
173430Y020	4,00	0,74	9

di periode yang akan berjalan. Pada PT. X, peramalan digunakan untuk memperkirakan permintaan spare part bulanan baik untuk permintaan domestik atau in-house maupun ekspor, dan terkecuali untuk jenis permintaan tertentu. Saat ini, fluktuasi permintaan spare part yang paling tinggi di PT. X berasal dari permintaan ekspor. Hal tersebut dibuktikan dengan hasil peramalan yang deviasinya masih besar dari permintaan aktual untuk ekspor setiap bulannya seperti pada Gambar 1.

Hasil peramalan spare part yang tidak akurat tersebut, ternyata memperparah problem lain yang sedang dihadapi oleh PT. X, seperti: tingkat on-time delivery yang rendah ketika terjadi underforecast karena tidak adanya stock function dan biaya inventory yang semakin besar ketika terjadi overforecast, terutama pada part berdimensi besar, karena fasilitas gudang yang belum efisien.

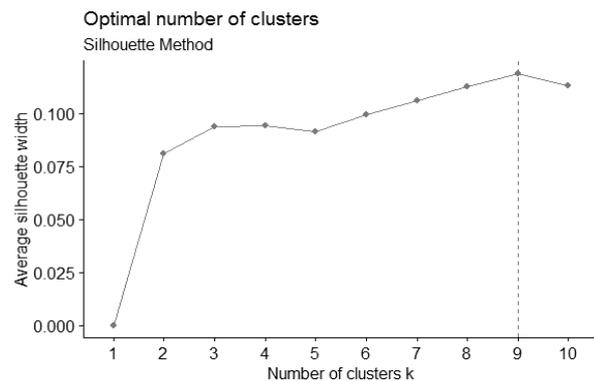
Hasil peramalan yang tidak akurat disebabkan pemilihan metode peramalan yang kurang tepat dengan pola permintaan spare part yang ada. Setiap data permintaan adalah time-series yang memiliki pola dan komponen-komponen, yaitu: tren, siklus, musiman, dan random, yang berbeda-beda [4]–[5]. Selain itu, pola permintaan spare part lebih kompleks karena memiliki variasi yang besar dari periode ke periode bahkan pada beberapa periode bisa bernilai nol [6]. Riwayat permintaan satu spare part dengan yang lainnya bisa sangat



Gambar 3. Struktur hipotesis dari Multi-Layer Perceptron (MLP) Artificial Neural Network dengan fungsi aktivasi dan dropout.

```
> dataset1
  Jan Feb Mar Apr May Jun Jul Aug Sep Oct Nov Dec
2018  0  0  0  0  0  2 120 351 740  0 394 669
2019 770 349 742 915 268 296 481  0  63  0 429 228
> (ADI <- idclass(t(dataset1),type="SBC")$p)
[1] 1.5
> (CV2 <- idclass(t(dataset1),type="SBC")$cv2)
[1] 0.4101521
> SBC.class(ADI,CV2)
[1] "Category: Intermittent"
```

Gambar 4. Proses klasifikasi Boylan pada salah satu data menggunakan software RStudio

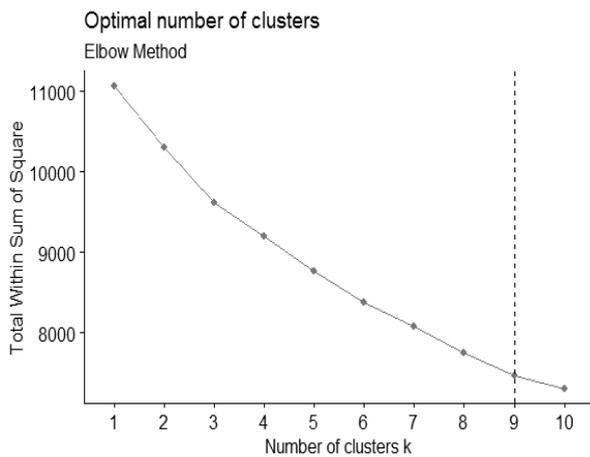


Gambar 5. Jumlah kluster optimal berdasarkan nilai SWC adalah 9

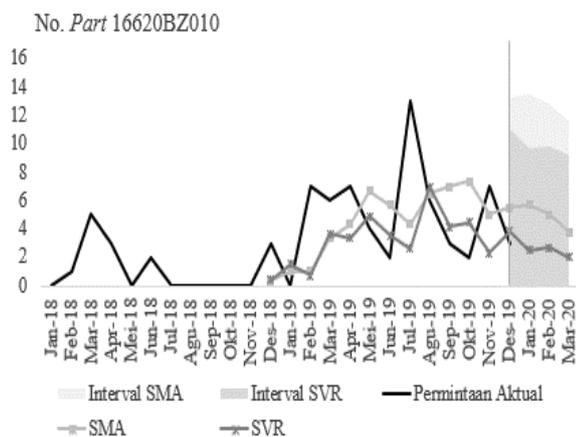
bervariasi, sehingga diperlukan adanya klasifikasi pola permintaan spare part.

Belum adanya sistem klasifikasi pola permintaan spare part menjadi salah satu faktor belum ditemukannya metode peramalan yang tepat dan akurat dalam menangani permintaan spare part di PT. X. Oleh karena itu, selama ini metode peramalan sederhana, yaitu Simple Moving Average (SMA), berdasarkan nilai paling besar dari rata-rata tiga dan enam bulan ke belakang, digunakan untuk meramalkan permintaan bulanan semua spare part di PT. X. Penyimpangan hasil peramalan disebabkan oleh parameter rata-rata pada SMA yang sensitif terhadap outlier [7]. Maka dari itu, metode SMA tidak cocok untuk permintaan spare part yang memiliki variasi besar. Akibatnya, mayoritas hasil peramalannya tidak akurat seperti pada Gambar 2 ketika diukur dengan kriteria Lewis [8].

Peramalan permintaan spare part dengan metode data-mining telah menunjukkan kesuksesan, seperti metode Support Vector Machine Regression (SVR) dan Artificial



Gambar 6. Jumlah kluster optimal berdasarkan nilai W_k adalah 9.



Gambar 7. Perbandingan hasil ramalan SMA dan SVR pada salah satu permintaan part.

Neural Network (ANN) [9][10][11]–[12]. Metode modifikasi *time-series*, seperti metode Croston dan modifikasinya yaitu: Syntetos-Boylan Approximation (SBA) dan Teunter-Syntetos-Babai Model (TSB), juga menunjukkan akurasi yang baik dalam meramalkan permintaan spare part bahkan mengungguli metode Moving Average dan Single Exponential Smoothing (SES) [13][14]–[15]. Dari alternatif-alternatif metode tersebut, dapat dilakukan analisis perbandingan untuk menentukan metode peramalan yang terbaik dalam menangani permintaan spare part di PT. X.

Secara umum, dalam penelitian ini klasifikasi Boylan dan teknik kluster *K-Medoids* akan diterapkan untuk mengklasifikasikan pola permintaan part di PT. X dari segmen ekspor ke Arab Saudi selama Januari 2018 – Desember 2019. Kemudian pada masing-masing klasifikasi, akan dilakukan peramalan dengan metode Croston, SBA, TSB, SVR, dan ANN. Pada akhirnya, kinerja semua metode akan dibandingkan dan divalidasi untuk menentukan metode peramalan yang paling akurat terhadap permintaan aktual dan robust terhadap berbagai perubahan data permintaan part. Selanjutnya dalam penelitian ini, metode pengumpulan dan pengolahan data dijelaskan pada METODE PENELITIAN, hasil pengolahan data dijelaskan pada HASIL DAN DISKUSI, dan KESIMPULAN.

Tabel 5. Kinerja model diukur dengan total MSE

	Croston	SBA	TSB	SVR*	ANN
Training	160.363,4	163.407,2	94.134,6	101.291,7	106.233,3
Testing	206.652,8	189.187,8	229.633,3	28.030,7	28.585,5

*Memiliki nilai error yang lebih kecil pada data training dan testing

Tabel 6. Robustness model diukur dengan p-value dari uji Kruskal-Wallis dan One-Way Anova

	Croston	SBA	TSB	SVR*	ANN
Training					
Family part	0,0000	0,0002	0,0000	0,0001	0,0001
Eksperimentasi	0,0000	0,0000	0,0000	0,0028	0,0002
Boylan	0,0000	0,0000	0,0000	0,0002	0,0020
K-Medoids	0,0000	0,0000	0,0000	0,0000	0,0000
Testing					
Family part	0,0290	0,1700	0,0031	0,0750	0,0260
Eksperimentasi	0,0000	0,0000	0,0000	0,0240	0,0510
Boylan	0,0000	0,0000	0,0000	0,0001	0,0002
K-Medoids	0,0000	0,0000	0,0000	0,0000	0,0002

Tabel 7. Perbandingan kinerja peramalan SVR dan SMA

	SVR	SMA	% Improvement
RMSE*	364,30	449,73	18,99
MAPE	1,73	26,27	93,41
SMAPE	0,7	0,73	4,10
MASE	0,73	1,34	45,52

*Bentuk akar kuadrat dari MSE

II. METODE PENELITIAN

A. Tahap Pengumpulan dan Pra-Pengolahan Data

Data yang dikumpulkan adalah data sekunder dari database riwayat order spare part di PT. X, yang terdiri dari fitur-fitur sebagai berikut: 1) Periode Order, 2) No. Part, 3) Nama Part, 4) Tujuan Pengiriman, 5) Dimensi Part, 6) Model Mobil, 7) Family Part, dan 8) Kuantitas Order.

Aktivitas peramalan dilakukan setiap bulan, sehingga Periode Order yang digunakan adalah bulanan dari Januari 2018 – Desember 2019. Model Mobil diidentifikasi dari No. Part, sedangkan Family Part diidentifikasi dari Nama Part. Family Part dibedakan menjadi empat macam, yaitu: 1) Eksterior, 2) Interior, 3) Suspensi, dan 4) Mesin. Masing-masing Family memiliki sumber kerusakan yang berbeda-beda. Perbedaan ini dievaluasi pada tahap pengembangan model. Tujuan Pengiriman ke Arab Saudi dipilih sebagai pilot penelitian sekaligus batasan penelitian dalam penelitian ini. Dimensi Part yang dipilih juga dibatasi pada Medium dan Large karena part dengan dimensi tersebut memiliki konsekuensi biaya kesalahan yang paling besar. Part dengan pola permintaan yang sulit diramalkan oleh metode SMA, lihat Inaccurate Forecast pada Gambar 2, juga diprioritaskan

penggunaannya, sehingga dengan ini ada tiga batasan yang dipertimbangkan. *Database* kemudian disaring berdasarkan ketiga batasan tersebut, sehingga diperoleh 1682 permintaan *part* sebagai calon data *training*. Tidak ada *missing value* pada *Kuantitas Order*. Nilai permintaan yang *outlier* tidak dibuang agar tidak menghilangkan karakteristik dari pola permintaan *part*.

B. Tahap Klasifikasi Pola Permintaan

1682 *part* kemudian diklasifikasikan berdasarkan pola permintaannya. Perbedaan klasifikasi *part* kemudian akan dievaluasi pada tahap pengembangan model. Ada dua metode yang digunakan, yaitu: Klasifikasi *Boylan* dan *K-Medoids*. Perbedaan kedua metode terletak pada ada atau tidak adanya label dan ukuran kemiripan yang digunakan. Sistematika kedua metode akan dijelaskan berikutnya.

1) Klasifikasi Boylan

Boylan membedakan pola permintaan *part* berdasarkan empat label, yaitu: 1) *Smooth*, 2) *Intermittent*, 3) *Erratic*, dan 4) *Lumpy* [16]. Klasifikasi ini menggabungkan pendekatan *Variance Partition*, *Eaves dan Kingsman*, dan *Intermittent Demand Estimation Procedure* [17]-[18]. Klasifikasi ini termasuk pendekatan yang umum digunakan dalam *spare part management* [19]. Ukuran kemiripan yang menentukan klasifikasi *part* ada dua, yaitu: *Average Inter-Demand Interval (ADI)* dan *Squared Coefficient of Variation (CV²)*.

$$ADI = \frac{\sum_{i=1}^n p_i}{n} \tag{1}$$

Pada (1), *i* menyatakan indeks periode permintaan, *n* adalah jumlah periode permintaan bernilai bukan nol, dan *p_i* adalah jumlah periode di antara dua permintaan bernilai bukan nol berturut-turut

$$CV^2 = \frac{\left(\sqrt{\frac{\sum_{i=1}^N (\varepsilon_i - \bar{\varepsilon})^2}{N}} \right)^2}{\bar{\varepsilon}^2} \tag{2}$$

Di mana $\bar{\varepsilon} = \frac{\sum_{i=1}^N \varepsilon_i}{N}$ (3)

Pada (2) dan (3), *i* menyatakan indeks periode permintaan, *N* adalah total periode permintaan yang diobservasi, *ε_i* adalah nilai permintaan pada periode *i*, dan *ε̄* adalah nilai rata-rata permintaan yang diobservasi. Secara spesifik, pola permintaan *part* diklasifikasi berdasarkan nilai *cut-off ADI* dan *CV²* dari *Boylan* pada [16]. Semakin besar *ADI*, semakin jarang frekuensi permintaan *part*, sedangkan semakin besar *CV²*, semakin fluktuatif volume permintaan *part*.

2) K-Medoids

K-Medoids termasuk teknik *Unsupervised Learning* dalam *Data Mining*, yaitu teknik pengelompokan tanpa guru atau tanpa label [20]. Karena tidak ada label, *part* dikelompokkan berdasarkan ukuran kemiripan fitur-fiturnya. Data permintaan adalah *univariate*, sehingga volume permintaan pada setiap periode menjadi fitur *part* (ada total 24 periode/fitur).

Kemiripan antar *part* diukur dengan kedekatan jarak setiap fitur. Ukuran jarak yang digunakan adalah jarak *Euclidean*.

$$d(P_1, P_j) = \sqrt{\sum_{i=1}^N (X_{1i} - X_{ji})^2} \tag{4}$$

Pada (4), *P* adalah *part*, *j* menyatakan indeks *part*, *d(P₁, P_j)* adalah jarak antara *part* ke-1 dan *part* ke-*j*, *i* menyatakan indeks periode permintaan, *N* adalah total periode permintaan, dan *X* adalah volume permintaan.

Part-part yang saling berdekatan dikelompokkan dalam satu kluster. Pada setiap kluster ada *Medoids*, yaitu *part* yang menjadi pusat kluster karena memberikan perbedaan jarak terkecil dengan anggota lainnya. Karena tidak ada label, maka jumlah kluster tidak definitif, dan anggota kluster bisa berlokasi secara iteratif, akan tetapi jumlah kluster optimal bisa diukur dengan parameter *Within-Cluster Dispersion (W_k)* dan *Silhouette Width Criterion (SWC)* [21][22]-[23].

W_k didefinisikan sebagai berikut:

$$SWC = \frac{1}{N} \sum_{j=1}^N s(j) \tag{6}$$

Di mana $s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}$ (7)

Pada (6) dan (7), *j* menyatakan indeks *Silhouette*, *N* adalah total *Silhouette*, *i* menyatakan indeks *part*, *s(i)* adalah nilai *Silhouette* dari *part* ke *i*, *a(i)* adalah rata-rata jarak antara *part i* dan *part* lain di kluster yang sama, dan *b(i)* adalah rata-rata jarak antara *part i* dan *part* lain di kluster lain. Semakin jauh jarak antar kluster, semakin besar nilai *SWC* dan semakin optimal jumlah kluster. Untuk menghindari hasil kluster yang bias karena variasi skala permintaan antar *part*, maka dilakukan Normalisasi *Min-Max* pada *data training*.

$$\hat{X}_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} * (BA - BB) + (BB) \tag{8}$$

Pada (8), *i* menyatakan indeks periode permintaan, *X_i* adalah volume permintaan pada periode *i*, *X_{min}* adalah volume permintaan terkecil, *X_{max}* adalah volume permintaan terbesar, *BA* adalah batas atas permintaan, dan *BB* adalah batas bawah permintaan.

C. Tahap Eksperimentasi Input Peramalan

Dalam *Data Mining*, suatu model prediksi yang *robust* harus memiliki *algorithmic stability*, yaitu stabilitas dari perubahan pada data *input* [24]-[25]. Untuk menguji hal ini, maka dilakukan perubahan-perubahan pada *data training*, seperti: *Seasonal Adjustment*, Transformasi *Box-Cox*, dan *Differencing*. Berbagai perubahan pada data *training* ini diuji pengaruhnya terhadap kinerja peramalan pada tahap pengembangan model. Data permintaan setelah *Seasonal Adjustment* dihilangkan pengaruh komponen musimannya [26].

Model Aditif:

$$X(t) - S(t) = T(t) + C(t) + I(t) \tag{9}$$

Model Multiplikatif:

$$\frac{X(t)}{S(t)} = T(t) \times C(t) \times I(t) \tag{10}$$

Pada (9) dan (10), *t* menyatakan indeks periode permintaan, *X* adalah volume permintaan, *S* adalah komponen musiman, *T* adalah komponen tren, *C* adalah komponen siklik, dan *I* adalah komponen *random*. Transformasi *Box-Cox* mengubah data permintaan menjadi bentuk *logaritma* atau *eksponensialnya* sehingga menjadi stasioner dalam varian [5].

$$w_t = \begin{cases} \ln(x_t), & \lambda = 0 \\ \frac{x_t^{\lambda-1}}{\lambda}, & \lambda \neq 0 \end{cases} \quad (11)$$

Pada (11), t menyatakan indeks periode permintaan, w_t adalah nilai permintaan setelah transformasi, x_t adalah nilai permintaan pada periode t , dan λ adalah konstanta yang tidak definitif dan nilai optimalnya dicari melalui program statistik. *Order Differencing* mengubah data permintaan menjadi stasioner dalam rata-rata [5]. Berikut adalah contoh *Differencing* orde pertama dan kedua:

$$x_t^{(1)} = x_t - x_{t-1} \quad (12)$$

$$y_t^{(2)} = y_t - 2y_{t-1} + y_{t-2} \quad (13)$$

Apabila masih ada komponen musiman, perlakuan *Differencing* menjadi:

$$x_t^{(1)} = x_t - x_{t-m} \quad (14)$$

Pada (12) – (14), t adalah indeks periode permintaan, x_t adalah nilai permintaan pada periode t , dan m adalah periode musiman.

D. Tahap Pengembangan Model Peramalan

Model peramalan dikembangkan dari metode: *Croston*, *SBA*, *TSB*, *SVR*, dan *ANN*. Kinerja model peramalan juga diuji dengan perbedaan *Family Part*, *Klasifikasi Part*, dan *Eksperimentasi Data Input*.

1) *Croston* dan Modifikasinya

Metode *Croston* tidak hanya meramalkan volume permintaan, tetapi juga interval periode antara dua permintaan, namun nilai keduanya hanya diperbarui ketika ditemui permintaan yang bernilai bukan nol [13].

$$Y_t = \begin{cases} Y_{t-1}, & X_{t-1} = 0 \\ \alpha \cdot X_{t-1} + (1 - \alpha) \cdot Y_{t-1}, & X_{t-1} > 0 \end{cases} \quad (15)$$

$$q_t = \begin{cases} q_{t-1} + 1, & X_{t-1} = 0 \\ 1, & X_{t-1} > 0 \end{cases} \quad (16)$$

$$p_t = \begin{cases} p_{t-1}, & X_{t-1} = 0 \\ \alpha \cdot q_{t-1} + (1 - \alpha) \cdot p_{t-1}, & X_{t-1} > 0 \end{cases} \quad (17)$$

$$F_t = \frac{Y_t}{p_t} \quad (18)$$

Pada (15) - (18), t menyatakan indeks periode permintaan selanjutnya, $t - 1$ menyatakan indeks periode permintaan saat ini, Y adalah permintaan estimasi, X adalah permintaan aktual, q adalah interval periode aktual, p adalah interval periode estimasi, F adalah ramalan permintaan, dan α adalah bobot yang nilainya [0,1]. Terdapat beberapa modifikasi pada sebagian persamaan untuk mengatasi bias pada metode *Croston* awal. Modifikasi pertama adalah *Syntetos-Boylan Approximation (SBA)* [14].

$$F_{t(SBA)} = (1 - \frac{\alpha}{2}) \frac{Y_t}{p_t} \quad (19)$$

Kemudian modifikasi terakhir adalah *Teunter-Syntetos-Babai Model (TSB)* [15].

$$p_{t(TSB)} = \begin{cases} (1 - \beta) \cdot p_{t-1}, & X_{t-1} = 0 \\ \beta + (1 - \beta) \cdot p_{t-1}, & X_{t-1} > 0 \end{cases} \quad (20)$$

$$F_{t(TSB)} = Y_t \cdot p_t \quad (21)$$

Pada (20), β adalah bobot yang nilainya [0,1]. Pada *TSB*, α dan β sama-sama digunakan pada persamaan. Pada (19) – (21), tidak ada perubahan definisi pada besaran lainnya. Hasil peramalan optimal bisa diperoleh dengan mengoptimalkan nilai α dan β , sehingga meminimalkan *Mean Squared Error (MSE)* dari hasil peramalan.

$$\min MSE = \frac{1}{N} \sum_{t=1}^N e_t^2 \quad (22)$$

$$\text{Di mana } e_t = x_t - y_t(t - 1) \quad (23)$$

Subject to:

$$0 \leq \alpha \leq 1 \quad (24)$$

$$0 \leq \beta \leq 1 \quad (25)$$

Pada (22) dan (23), t menyatakan indeks periode permintaan, N adalah total periode permintaan, e_t adalah *error* peramalan pada periode t , x adalah permintaan aktual, dan y adalah permintaan estimasi.

2) *Support Vector Machine Regression (SVR)*

SVR termasuk teknik *Supervised Learning* dalam *Data Mining*, yaitu teknik prediksi berdasarkan fitur-fitur dan label data yang sudah ada [21]. Data permintaan adalah *univariate*, sehingga perlu ditransformasi dengan teknik *Windowing* agar memiliki fitur dan label. Jika s adalah himpunan permintaan yang terdiri dari $s = [1,2,3,4,5,6,7,8,9]$ maka dengan $k = 3$, hasil transformasinya sebagai berikut.

$$[s[k - 3], s[k - 2], s[k - 1]] \rightarrow s[k] \quad (26)$$

$$[x_1, x_2, x_3] \rightarrow [y] \quad (27)$$

$$\begin{bmatrix} 1 & 2 & 3 \\ 2 & 3 & 4 \\ 3 & 4 & 5 \\ \vdots & \vdots & \vdots \\ 6 & 7 & 8 \end{bmatrix} \rightarrow \begin{bmatrix} 4 \\ 5 \\ 6 \\ \vdots \\ 9 \end{bmatrix}$$

Pada (26), k adalah *time window*, $s[k]$ adalah anggota himpunan s dengan indeks ke- k . Pada (27), x adalah fitur dan y adalah label *ground truth*. Menyelesaikan suatu problem dalam *SVR* ekuivalen dengan menyelesaikan bentuk dual dari persamaan optimasi kuadrat linear pada (28) – (31) [21].

$$\max -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) - \sum_{i=1}^m y_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^m (\alpha_i - \alpha_i^*) \quad (28)$$

Subject to:

$$\sum_{i=1}^m (\alpha_i - \alpha_i^*) = 0 \quad (29)$$

$$0 \leq \alpha_i \leq C, i = 1, 2, \dots, m \quad (30)$$

$$0 \leq \alpha_i^* \leq C, i = 1, 2, \dots, m \quad (31)$$

Pada (28) – (31), i adalah indeks data, m adalah banyak data, a adalah *Lagrange Multiplier*, $K(x_i, x_j)$ adalah fungsi kernel, x_i adalah data *training*, x_j adalah data *testing*, y adalah label *ground truth*, ε adalah konstanta yang nilainya tidak definitif, dan C adalah biaya penalti atas kesalahan hasil prediksi. Fungsi kernel berfungsi untuk mengatasi nonlinearitas dengan memetakan data pada dimensi yang lebih tinggi. Fungsi kernel yang digunakan adalah Fungsi *Radial Basis* sebagai berikut.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (32)$$

Pada (32), γ adalah konstanta yang bernilai $(0, \infty]$. Dengan menyelesaikan (28) – (31), maka nilai peramalan bisa diperoleh dengan persamaan regresi berikut.

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (33)$$

Pada (33), $f(x)$ adalah fungsi regresi, b adalah *intercept*, dan tidak ada perubahan definisi pada besaran lainnya. Pada SVR, ε , γ , dan C disebut *Hyperparameter*, yaitu parameter yang nilainya tidak definitif. Hasil peramalan optimal bisa diperoleh dengan melakukan *Hyperparameter Tuning*, yaitu menyesuaikan nilai *Hyperparameter* secara *heuristik*, sehingga meminimalkan *MSE* (lihat pada (22)). Rentang nilai parameter SVR 9 Dapat dilihat pada Tabel 2) yang digunakan dalam penelitian ini adalah sebagai berikut. $*[0; 1; 1]$ berarti bernilai 0 sampai 1 dengan perubahan +1. Data yang digunakan untuk mengembangkan model SVR dibagi menjadi 60% data *training*, 15% data validasi, dan 25% data *testing*.

3) Artificial Neural Network (ANN)

ANN memproses semua *input* pada *input layer* sehingga menghasilkan *output* dengan melewatkannya melalui *hidden layer* [21]. Setiap *layer* berturut-turut menghasilkan *output* sebagai *input* untuk *layer* selanjutnya hingga *output* terakhir di *output layer* dapat dilihat pada Gambar 3. *Output* pada *layer ANN* dihitung dengan fungsi penjumlahan pada (34).

$$f(v) = f(\sum_{i=1}^k \sum_{j=1}^n w_{ij} x_{ij} + w_0 x_0) \quad (34)$$

Pada (34), $f(v)$ adalah estimasi *output*, i menyatakan indeks simpul awal, j menyatakan indeks simpul tujuan, k dan n adalah jumlah *neuron* pada masing-masing *layer*, w_{ij} adalah bobot yang nilainya *random*, x_{ij} adalah data dari simpul i ke j , w_0 adalah bias yang nilainya *random*, dan x_0 bernilai 1. Pada kasus peramalan, salah satu struktur ANN yang bisa digunakan adalah *Multi-Layer Perceptron (MLP)* dengan *output* tunggal [27]. Pada data nonlinear, agar *output ANN* tetap positif maka digunakan suatu fungsi aktivasi seperti *Rectified Linear Unit (ReLU)* pada (35).

$$f(v) = \begin{cases} 0, & v < 0 \\ f(v), & v \geq 0 \end{cases} \quad (35)$$

Nilai bobot dan bias yang *random* dihitung nilai optimalnya melalui suatu algoritma optimasi, salah satunya adalah *RMSprop*. Pada suatu algoritma optimasi, nilai bobot dan bias diperbarui dengan cara berikut [12].

$$w_{t+1} = w_t - \eta g_t \quad (36)$$

$$\text{Di mana } g_t = \nabla_w Q(e_t, w_t) \quad (37)$$

Pada (36) dan (37), t adalah indeks iterasi, w_{t+1} adalah bobot atau bias baru, w_t adalah bobot atau bias awal, η adalah *learning rate* yang nilainya tidak definitif, dan g_t adalah gradien yang didefinisikan sebagai turunan dari ukuran *error* prediksi e_t terhadap w . Pada ANN, hasil peramalan optimal bisa diperoleh dengan menyesuaikan *hyperparameter* η , menyesuaikan jumlah *hidden layer* dan *neuron*, mengoptimalkan nilai bobot dan bias awal, serta mengatur *dropout rate* dan regularisasi.

Bobot dan bias awal yang optimal bisa dihitung dengan distribusi tertentu seperti *Glorot Uniform* [28].

$$w_{t=0} = U(-\sqrt{\frac{6}{w_{in}-w_{out}}}, \sqrt{\frac{6}{w_{in}-w_{out}}}) \quad (38)$$

Pada (38), w_{in} dan w_{out} adalah dimensi dari bobot pada *input* dan *output layer*. Ringkasan struktur ANN dan rentang nilai parameter yang digunakan dalam penelitian dapat dilihat pada Tabel 3. Data yang digunakan untuk mengembangkan model ANN dibagi menjadi 60% data *training*, 15% data validasi, dan 25% data *testing*.

E. Tahap Implementasi Model Peramalan

Setiap model peramalan akan diukur *forecasting error* dan *robustnessnya*. Ukuran *error* yang digunakan untuk menyeleksi model adalah *MSE*. Ukuran *robustness* ditinjau berdasarkan hasil uji signifikansi pengaruh perbedaan *Family Part*, *Klasifikasi Part*, dan *Eksperimentasi Input* terhadap *MSE* model. Uji signifikansi yang digunakan adalah uji *Kruskal-Wallis* dan *One-Way Anova* [29]. Kandidat model terbaik memiliki nilai *MSE* yang kecil dan tidak terpengaruh secara signifikan terhadap perbedaan pada data.

Model terbaik kemudian diimplementasikan untuk peramalan multi-periode dan dibandingkan kinerjanya dengan hasil peramalan metode *SMA*. Ukuran *error* selain *MSE*, yaitu: *MAPE*, *SMAPE*, dan *MASE*, juga digunakan sebagai perbandingan. Semua pengolahan data dan uji statistik dalam penelitian ini dieksekusi menggunakan Bahasa Pemrograman R versi 4.0.0 dan *software* RStudio. Baik R maupun RStudio bersifat *open-source*.

III. HASIL DAN DISKUSI

A. Hasil Klasifikasi Boylan dan Klaster K-Medoids

Perbedaan klasifikasi *part* dalam peramalan berfungsi untuk mengidentifikasi karakteristik pola permintaan dan mempermudah pengambilan keputusan pada hasil peramalan. Misalnya dalam menentukan stok pengaman, setelah mengetahui klasifikasi *part*, maka persentase stok pengaman bisa ditentukan berbeda-beda menyesuaikan karakteristik pola permintaan *part*. Proses klasifikasi Boylan dapat dilihat pada Gambar 4.

Hasil klasifikasi Boylan menunjukkan bahwa mayoritas *part* di PT. X adalah *Lumpy* (54,76%) dan *Intermittent* (37,10%), sisanya adalah *Erratic* (6,42%), dan *Smooth* (1,72%). Karakter permintaan *Lumpy* memiliki frekuensi yang rendah dan volume yang fluktuatif. Hal tersebut menunjukkan bahwa mayoritas *part* di PT. X memiliki *lifetime* yang panjang, oleh karena itu, jumlah datanya sedikit dan lonjakan permintaan sering terjadi pada suatu periode. Lonjakan ini bisa menimbulkan *outlier* dan menyebabkan hasil peramalan yang ekstrem. Oleh karena itu metode peramalan yang tidak sensitif terhadap *outlier* lebih dikehendaki.

Hasil klaster *K-Medoids* menunjukkan bahwa terdapat sembilan klaster yang membedakan pola permintaan *part* di PT. X. Persentase masing-masing klaster juga lebih merata, yaitu klaster 3 (17,78%), klaster 1 (17,72%), klaster 4 (16,76%), klaster 2 (9,45%), klaster 8 (8,92%), klaster 6 (8,74%), klaster 5 (7,31%), klaster 8 (6,90%), dan klaster 9 (6,42%). Pada Gambar 5 dan Gambar 6, membedakan *part* ke dalam 9 klaster ditunjukkan lebih optimal dibandingkan ke dalam 4 klaster. Hal ini membuktikan bahwa *K-Medoids* lebih efektif dalam menangkap banyak perbedaan pada

permintaan *part* dibandingkan klasifikasi *Boylan*. Pada setiap klaster, ada satu *part* yang menjadi pusat klaster, sehingga merepresentasikan karakter klaster tersebut. Masing-masing *part* tersebut dapat dilihat pada Tabel 4.

B. Hasil Pengembangan Model

Hasil kinerja peramalan yang diukur dengan *MSE* dari semua model pada data *training* dan *testing* adalah sebagai berikut. Pada Tabel 5, *SVR* memiliki *forecasting error* yang lebih kecil dibandingkan dengan model lainnya. Hasil uji signifikansi pengaruh perbedaan pada data *input* terhadap *MSE* semua model adalah sebagai berikut. Semakin mendekati 0,05 pengaruh perbedaan data semakin tidak signifikan.*Lebih tidak sensitif terhadap pengaruh perbedaan data. Pada Tabel 6, ukuran yang digunakan adalah *p-value*. Nilai *p-value* yang semakin mendekati atau melebihi 0,05 menunjukkan pengaruh yang tidak signifikan, sedangkan nilai *p-value* yang kurang dari 0,05 menunjukkan pengaruh yang signifikan. Pada *SVR*, mayoritas pengaruh perbedaan data tidak terlalu signifikan, sehingga keduanya lebih *robust* dibandingkan dengan model lainnya.

C. Hasil Implementasi Model

Model *SVR* diimplementasikan untuk peramalan tiga periode ke depan ($h = 3$) dan dibandingkan kinerjanya dengan metode *existing*, yaitu *SMA*. Pada Gambar 7 diberikan satu contoh implementasi peramalan yang menunjukkan bahwa metode *SMA* sensitif dengan fluktuasi permintaan yang tinggi, sehingga mengestimasi permintaan terlalu tinggi, sedangkan *SVR* cenderung lebih stabil. Secara keseluruhan, perbandingan kinerja *SVR* dan *SMA* diukur dengan *MSE*, *MAPE*, *SMAPE*¹, dan *MASE*² adalah sebagai berikut. Pada Tabel 7, *SVR* mengungguli *SMA* pada semua ukuran error, bahkan memperbaiki kesalah peramalan *SMA* sebesar 18.99% apabila ditinjau dari *MSE*.

IV. KESIMPULAN

Penelitian ini menjelaskan bahwa klasifikasi pola permintaan *part* perlu dilakukan sebelum melakukan peramalan. Hal tersebut karena respon yang berbeda perlu diberikan terhadap hasil peramalan dari klasifikasi *part* yang berbeda pula, misalnya respon ketika melebihi hasil peramalan untuk stok pengaman. Penentuan persentase stok pengaman pada permintaan *Lumpy* yang frekuensinya rendah dan fluktuasinya tinggi tentu berbeda dengan permintaan *Smooth* yang frekuensinya tinggi dan stabil. Maka, hasil klasifikasi *part* dapat berfungsi sebagai pendukung dalam pengambilan keputusan terhadap hasil peramalan, seperti menentukan persentase stok pengaman. Berdasarkan hasil *K-Medoids* diketahui bahwa, klasifikasi pola permintaan *part* yang ada di PT. X ke dalam 9 macam pola permintaan lebih optimal dibandingkan dengan 4 macam pola permintaan seperti klasifikasi *Boylan*. Hal ini dibuktikan dengan ukuran kemiripan *SWC* dan W_k yang lebih baik dan persentase *part* yang lebih merata. Dari 4 model peramalan yang dievaluasi, yaitu: *Croston*, *SBA*, *TSB*, *SVR*, dan *ANN*, diketahui bahwa *SVR* memiliki kinerja yang paling unggul karena memiliki total *MSE* yang lebih kecil dan lebih *robust* terhadap perbedaan data *input*. Keunggulan *SVR* juga terbukti ketika

diimplementasikan untuk meramalkan permintaan tiga periode ke depan dan dibandingkan kinerjanya dengan metode *existing*, yaitu *SMA*. *SVR* bahkan memperbaiki kesalahan peramalan *SMA* sebesar 19% apabila ditinjau dari ukuran *error MSE*.

Hasil dari penelitian ini diharapkan dapat menjadi referensi dalam memperbaiki sistem peramalan yang ada di PT. X. Peramalan yang dilakukan dalam penelitian ini hanya berdasarkan pada variabel tunggal (*univariate*) yaitu permintaan *part*. Oleh karena itu, peramalan *multivariate*, dengan melibatkan variabel-variabel eksogen yang mempengaruhi permintaan *part*, sangat memungkinkan untuk dilakukan sebagai pengembangan dari penelitian ini selanjutnya.

SMAPE = Symmetric Mean Absolute Percentage Error
² *MASE* = Mean Absolute Scaled Error

LAMPIRAN

A. Ukuran Kesalahan Peramalan yang Digunakan

1. Root Mean Square Error (RMSE)

$$MSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2} \tag{39}$$

2. Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100 \tag{40}$$

3. Symetric Mean Absolute Percentage Error (SMAPE)

$$SMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{(A_t + F_t)} \tag{41}$$

4. Mean Absolute Scaled Error (MASE)

$$MASE = \frac{1}{n} \sum_{t=1}^n \left(\frac{|A_t - F_t|}{\frac{1}{n-1} \sum_{t=2}^n |A_t - A_{t-1}|} \right) \tag{42}$$

Keterangan:

- i = Indeks periode permintaan
- n = Total periode permintaan
- A_t = Permintaan aktual pada periode t
- F_t = Ramalan permintaan pada periode t

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada PT. Toyota Motor Manufacturing Indonesia yang telah memberikan kesempatan, sarana, dan prasarana kepada penulis untuk melakukan penelitian ini. Khususnya kepada pihak-pihak yang menjabat di After Sales and Service Part Division yang telah menjadi mentor dan narasumber penulis dalam penelitian ini.

DAFTAR PUSTAKA

[1] G. Loukmidis and H. Luczak, *Life Cycle Oriented Planning Strategies for Spare Part Needs,* " in *Successful with After Sales Service: Business Strategies for Service Management and Spare Part Logistics.*

- Heidelberg: Springer-Verlag, 2006.
- [2] F. Klug, *Logistics Management in The Automotive Industry: Basics of Logistics in Automotive Engineering*, 2nd ed. Heidelberg: Springer-Verlag, 2018.
- [3] P. Jiang, X. Liu, Y. Huang, and Y. Yuan, "An adaptive data-driven model for erratic demand forecasting," *IFAC-PapersOnLine*, vol. 50, no. 1, pp. 9020–9025, 2017, doi: 10.1016/j.ifacol.2017.08.1584.
- [4] S. Chopra and P. Meindl, *Supply Chain Management: Strategy, Planning, and Operation*, 6th ed. Essex, NE: Pearson Education, 2016.
- [5] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed. Australia: Monash University, 2020.
- [6] N. Altay and L. A. Litteral, *Spare Part Management: Demand Forecasting and Inventory Control*. London: Springer-Verlag, 2011.
- [7] R. De Nijs and T. L. Klausen, "On the expected difference between mean and median," *Electron. J. Appl. Stat. Anal.*, vol. 6, no. 1, pp. 110–117, 2013, doi: 10.1285/i20705948v6n1p110.
- [8] C. D. Lewis, *Industrial and Business Forecasting Methods*. London: Butterworth Scientific, 1982.
- [9] Z. Hua and B. Zhang, "A hybrid support vector machines and logistic regression approach for forecasting intermittent demand of spare parts," *Appl. Math. Comput.*, vol. 181, no. 2, pp. 1035–1048, Oct. 2006, doi: 10.1016/j.amc.2006.01.064.
- [10] A. Turkyilmaz and G. O. Kaya, "Intermittent demand forecasting using data mining techniques," *Appl. Comput. Sci.*, vol. 14, no. 2, pp. 38–47, 2018, doi: 10.23743/acs-2018-11.
- [11] M. Sahin, R. Kizilaslan, and O. F. Demirel, "Forecasting aviation spare parts demand using croston based methods and artificial neural networks," *J. Econ. Soc. Res.*, vol. 15, no. 2, pp. 1–21, 2013.
- [12] R. Henkelmann, "A deep learning based approach for automotive spare part demand forecasting," Otto von Guericke Universitat Magdeburg, 2018.
- [13] J. D. Croston, "Forecasting and stock control for intermittent demands," *Oper. Res. Q.*, vol. 23, no. 3, pp. 289–303, Sep. 1972, doi: 10.1057/jors.1972.50.
- [14] A. A. Syntetos and J. E. Boylan, "The accuracy of intermittent demand estimates," *Int. J. Forecast.*, vol. 21, no. 2, pp. 303–314, 2005, doi: 10.1016/j.ijforecast.2004.10.001.
- [15] R. H. Teunter, A. A. Syntetos, and M. Z. Babai, "Intermittent demand: linking forecasting to inventory obsolescence," *Eur. J. Oper. Res.*, vol. 214, no. 3, pp. 606–615, 2011, doi: 10.1016/j.ejor.2011.05.018.
- [16] A. Syntetos and et al, "On the categorization of demand patterns," *J. Opl Res Soc.*, vol. 56, pp. 495–503, 2005.
- [17] T. M. Williams, "Stock control with sporadic and slow-moving demand," *J. Oper. Res. Soc.*, vol. 35, no. 10, pp. 939–948, 1984, doi: 10.1057/jors.1984.185.
- [18] A. H. C. Eaves and B. G. Kingsman, "Forecasting for the ordering and stock-holding of spare parts," *J. Oper. Res. Soc.*, vol. 55, no. 4, pp. 431–437, Mar. 2004, doi: 10.1057/palgrave.jors.2601697.
- [19] G. Loukmidis, "Adaptive Spare Part Requirements Planning," RWTH Aachen University, 2014.
- [20] B. Santosa and A. Umam, *Data Mining dan Big Data Analytics: Teori dan Implementasi Menggunakan Python & Apache Spark*, 2nd ed. Yogyakarta: Penebar Media Pustaka, 2018.
- [21] T. M. Kodinariya and P. R. Makwana, "Review on determining number of cluster in k-means clustering," *Int. J. Adv. Res. Comput. Sci. Manag. Stud.*, vol. 1, no. 6, pp. 90–9, 2013.
- [22] P. Roelofsen, "Time-series clustering," Vrije Univ, Amsterdam, Netherlands, 2018.
- [23] H. Xu and S. Mannor, "Robustness and generalization," *COLT 2010 - 23rd Conf. Learn. Theory*, pp. 503–515, 2010.
- [24] C. Chen, "Robustness properties of some forecasting methods for seasonal time series: A Monte Carlo study," in *International Journal of Forecasting*, Jun. 1997, vol. 13, no. 2, pp. 269–280, doi: 10.1016/S0169-2070(97)00014-9.
- [25] D. C. Montgomery, C. L. Jennings, and M. Kulahci, *Introduction to Time-Series Analysis & Forecasting*. New Jersey: Wiley & Sons, Inc, 2008.
- [26] J. Shahrabi, S. S. Mousavi, and M. Heydar, "Supply chain demand forecasting: a comparison of machine learning techniques and traditional methods," *J. Appl. Sci.*, vol. 9, no. 3, pp. 521–527, 2009, doi: 10.3923/jas.2009.521.527.
- [27] X. Glorot and Y. Bengio, "Understanding the difficulty of training deep feed forward neural networks," *J. Mach. Learn. Res.*, vol. 9, pp. 249–256, 2010.
- [28] W. H. Kruskal and W. A. Wallis, "Use of ranks in one-criterion variance analysis," *J. Am. Stat. Assoc.*, vol. 47, no. 260, pp. 583–621, 1952, doi: 10.1080/01621459.1952.10483441.
- [29] G. W. Snedecor and W. G. Cochran, *Statistical Methods*, 6th ed. Iowa: Iowa State University Press, 1967.