

## Penentuan *Reorder Point* dan *Safety Stock* pada *Consumable Material* Berdasarkan Peramalan Menggunakan *Artificial Neural Network*

Ahmad Fauzi Ridwan<sup>1\*</sup>, Muhammad Ahsan<sup>2</sup>

<sup>1)</sup> Magister Manajemen Teknologi, Institut Teknologi Sepuluh Nopember  
Jl. Cokroaminoto 12A, Surabaya, 60264, Jawa Timur  
Email: af.ridwan@yahoo.com

<sup>2)</sup> Departemen Statistika, Institut Teknologi Sepuluh Nopember  
Kampus Sukolilo, Surabaya, 60117, Jawa Timur  
Email: muh.ahsan@its.ac.id

\* *Corresponding Author*

### ABSTRAK

Ketersediaan material guna mendukung kegiatan operasional sangatlah penting, salah satunya adalah kegiatan pemeliharaan pada PT. XYZ. Material-material *consumable* seperti *oxygen*, *acetylene*, elektroda las, dan lain-lain harus selalu tersedia demi menjaga keberlangsungan kegiatan pemeliharaan dan mencegah *downtime* yang lama. Namun dalam kenyataannya, sering kali material-material yang dibutuhkan mengalami *stock out* atau stok habis akibat tidak adanya penentuan nilai titik pemesanan kembali atau *reorder point* (ROP) dan stok pengaman atau *safety stock* (SS) berdasarkan peramalan permintaan. Material yang *stock out* akan menghambat pekerjaan pemeliharaan dan berpotensi membuat durasi *downtime* yang lebih lama. Untuk mengatasi hal tersebut, dibutuhkan analisis untuk meramalkan kebutuhan jumlah material dengan menggunakan metode peramalan deret waktu yaitu, ANN (*Artificial Neural Network*). Peramalan dari arsitektur terbaik akan menentukan jumlah masing-masing *reorder point* dan *safety stock* dari masing-masing material. Hasil yang didapat adalah pada material *acetylene* menggunakan arsitektur 12-2-1 dengan MSE sebesar 74.79, MAPE sebesar 18.37%, ROP sebesar 39 pcs, dan *safety stock* sebesar 24 pcs. Kemudian pada material *oxygen* menggunakan arsitektur 12-4-1 dengan MSE sebesar 224.11, MAPE sebesar 16.51%, ROP sebesar 181 pcs, dan *safety stock* sebesar 115 pcs.

**Kata kunci:** ANN, stok habis, titik pemesanan kembali, stok pengaman.

### ABSTRACT

*The availability of materials to support operational activities is very important, one of which is maintenance activities at PT XYZ. Consumable materials such as oxygen, acetylene, welding electrodes, and others must always be available to maintain the continuity of maintenance activities and prevent long downtime. But in reality, the required materials are often stocked out due to the absence of determining the reorder point (ROP) and safety stock (SS) values based on demand forecasting. Materials that are stocked out will hamper maintenance work and potentially create a longer downtime duration. To overcome this, an analysis is needed to forecast the need for the amount of material using a time series forecasting method, namely, ANN (Artificial Neural Network). Forecasting from the best architecture will determine the amount of each reorder point and safety stock of each material. The results obtained are on acetylene material using 12-2-1 architecture with MSE of 74.79, MAPE is 18.37%, ROP is 39 pcs, and safety stock is 24 pcs. Then the oxygen material uses a 12-4-1 architecture with an MSE is 224.11, MAPE is 16.51%, ROP is 181 pcs, and safety stock is 115 pcs.*

**Keywords:** ANN, stock out, reorder point, safety stock.

### I. PENDAHULUAN

PT. XYZ merupakan salah satu perusahaan tambang batu bara di Indonesia. Pada proses penambangan PT. XYZ memiliki *Coal Processing Plant* (CPP) untuk meremukkan batu bara sehingga memiliki ukuran sesuai kebutuhan pelanggan. Produktifitas dari CPP perlu dijaga guna menunjang ketercapaian target produksi PT. XYZ. Salah satu usaha untuk menjaga produktifitas CPP adalah dengan melakukan kegiatan pemeliharaan yang efektif, hal ini merupakan tanggung jawab departemen *Fix Plant Maintenance* (FPM) dalam menjaga kehandalan dan ketersediaan unit CPP.

Kegiatan pemeliharaan yang dilakukan oleh departemen FPM PT. XYZ meliputi *predictive maintenance*, *preventive*, *corrective*, dan *overhaul maintenance*. Semua kegiatan pemeliharaan departemen pemeliharaan tak lepas dari pekerjaan panas, pekerjaan ini berkaitan dengan pengelasan, pemotongan dengan busur api, dan penggerindaan. Pekerjaan panas ini biasanya dilakukan untuk pemasangan pelat tahan aus, pembongkaran unit, pemasangan unit, fabrikasi, dan lain-lain. Kebutuhan material pekerjaan panas sangatlah penting guna menunjang produktivitas pabrik. Tabung *Oxygen*, *Acetylene*, dan elektroda las adalah contoh material yang dibutuhkan dalam pekerjaan panas. Material-material *consumable* tersebut dikelola oleh departemen logistik. Apabila material-material tersebut tidak terpenuhi, maka akan menghambat kegiatan pemeliharaan dan akan berisiko membuat durasi *downtime* yang lebih lama. Dan juga kekurangan material yang dibutuhkan mengakibatkan pesanan darurat yang jauh lebih mahal dan dapat menyebabkan penundaan pekerjaan (Zhu et al., 2022).

Permasalahan yang sering dialami oleh departemen FPM adalah material-material yang dibutuhkan untuk pekerjaan panas sering kali *stock out*. Hal ini dikarenakan tidak adanya peramalan kebutuhan material-material *consumable* dan juga tidak adanya parameter *reorder point* dan *safety stock*. Perencanaan stok yang tidak akurat akan menyebabkan tidak terpenuhinya *reorder point* dan kurangnya persediaan. Menurut Rodrigues et al. (2020) kontrol persediaan bergantung pada kualitas prediksi permintaan di masa depan.

Dalam menyelesaikan masalah tersebut diperlukan peramalan material yang tepat untuk memprediksi kebutuhan material di masa yang mendatang. Beberapa metode peramalan dengan pendekatan statistik telah diperkenalkan seperti ARIMA, *exponential smoothing*, *moving average*, dan lain sebagainya, namun metode peramalan tradisional tersebut tidak dapat menangkap ketidaklinearan data (Gutierrez et al., 2008). Untuk mengatasi keterbatasan metode peramalan tradisional, metode peramalan *artificial neural network* dapat dijadikan metode yang menjanjikan (Ali Salamai et al., 2022) dan dapat mengatasi data yang tidak linear (Rathipriya et al., 2023).

Penelitian mengenai peramalan permintaan telah dilakukan oleh peneliti-peneliti sebelumnya. Hu (2020) melakukan penelitian tentang peramalan permintaan untuk material magnesium untuk menjamin ketersediaan bahan baku bagi industri elektronik, dalam penelitian tersebut dilakukan dengan peramalan dengan metode *Neural Network*, hasil yang didapat adalah model terbaik GRA-NNGM (1,1) dengan MAPE sebesar 7,83%. Ifraz et al. (2023) melakukan penelitian tentang peramalan permintaan untuk suku cadang angkutan bus untuk menjamin ketersediaan untuk kegiatan pemeliharaan dan melakukan efisiensi agar tidak *over stock* ataupun *stock out*, dalam penelitian tersebut dilakukan dengan peramalan dengan metode *Artificial Neural Network (ANN)*, *Regression-Based methods*, *Rule-Based methods*, *Tree-Based methods*, hasil yang didapat adalah model terbaik adalah ANN dengan MAPE sebesar 4,71%. Shi (2022) melakukan penelitian tentang peramalan permintaan untuk menentukan kuantitas pemesanan berdasarkan beberapa jenis variabel seperti pendapatan *fiscal*, *consumer price index*, *historical sales volume*, dan lain sebagainya, dalam penelitian tersebut dilakukan dengan peramalan dengan metode *Lasso*, *Polynomial*, dan *Random Forest*, hasil yang didapat adalah model terbaik adalah *Random Forest* dengan MSE sebesar 572,36. Istikmalatun et al (2020) melakukan penelitian tentang merencanakan kebutuhan bahan baku di industri roti dengan peramalan *moving average* dan hasil peramalan tersebut menjadi input untuk penentuan kebutuhan bahan baku menggunakan beberapa teknik *lot sizing*, hasil yang didapat *least total cost* menjadi metode yang efisien. Susetyo et al. (2020) melakukan penelitian perencanaan produksi kaos agar tidak *over stock* maupun *stock out* dengan menggunakan beberapa peramalan seperti *simple average*, *moving average*, *weighted moving average*, *single exponential smoothing*, *double exponential smoothing*, dalam penelitian tersebut *single exponential smoothing* menjadi peramalan terbaik dan hasil peramalan tersebut menjadi *input fuzzy inference system* untuk mendapatkan jumlah produksi yang optimal.

Berdasarkan penelitian-penelitian sebelumnya metode peramalan dapat digunakan untuk menganalisa kebutuhan material. Pada penelitian ini akan dilakukan peramalan material *consumable* antara lain tabung *oxygen* dan *acetylene*, metode untuk peramalannya akan menggunakan *Feed Forward Backpropagation*, peramalan dengan hasil arsitektur terbaik akan digunakan untuk menentukan nilai *reorder point* dan *safety stock*.

## II. METODE PENELITIAN

Data pada penelitian ini merupakan data sekunder yang didapat dari basis data PT. XYZ yang berisi data permintaan material tabung *oxygen*, *acetylene* dari periode Januari 2018 sampai dengan Desember 2022.

Data diolah dengan menggunakan *software Matlab R2014* untuk menjalankan algoritma *Feed Forward Backpropagation*. Berikut adalah tahapan-tahapan penelitian pada setiap material:

1. Melakukan data visualisasi dan eksplorasi.
2. Melakukan normalisasi data dengan menggunakan rumus:

$$Y = \frac{0,8(X - b)}{a - b} + 0,1 \quad (1)$$

Dimana,

- $Y$  : Nilai hasil normalisasi
- $X$  : Nilai asli
- $a$  : Nilai maksimum data asli
- $b$  : Nilai minimum data asli

3. Membagi data *training* dan data *testing*. Data *training* terdiri dari bulan Januari 2018 sampai dengan Desember 2021, data *testing* terdiri dari bulan Januari 2022 sampai dengan Desember 2022.
4. Merancang pemodelan ANN atau JST (Jaringan Saraf Tiruan) berdasarkan data *training* dengan menentukan jumlah *hidden* layer dari percobaan *hidden layer* berjumlah 1 sampai dengan 10. Berikut adalah rancangan arsitektur yang digunakan dalam penelitian ini:
  - Fungsi jaringan menggunakan *Feed Forward Backpropagation (newff)*.
  - Fungsi aktivasi lapisan tersembunyi menggunakan *Logistik Sigmoid (logsig)*.
  - Fungsi aktivasi lapisan keluaran menggunakan *Linear (purelin)*.
  - Fungsi pembelajaran menggunakan *Momentum and Adaptive Learning Rate Backpropagation (traingdx)*.
5. Menentukan nilai parameter pembelajaran dengan detail sebagai berikut:
  - $net.performFcn$  = mse
  - $net.trainParam.goal$  = 0,001
  - $net.trainParam.show$  = 20
  - $net.trainParam.epochs$  = 1000
  - $net.trainParam.mc$  = 0,95
  - $net.trainParam.lr$  = 0,1
6. Melakukan peramalan dari arsitektur yang telah dibuat.
7. Menguji hasil peramalan dengan data *testing* berdasarkan MAPE (*Mean Absolute Percentage Error*) dan MSE (*Mean Squared Error*) (Dristiana & Sukmono, 2015).

$$MAPE = \frac{\sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{Z_t}}{n} \times 100\% \quad (2)$$

$$MSE = \frac{\sum_{t=1}^n (Z_t - \hat{Z}_t)^2}{n} \quad (3)$$

Dimana,

- $Z_t$  : Nilai aktual pada periode  $t$
- $\hat{Z}_t$  : Nilai peramalan pada periode  $t$
- $n$  : Banyaknya data

8. Memeriksa *tracking signal* untuk memonitor dan mengukur kinerja stok atau persediaan. *Tracking signal* mengukur perbedaan antara perkiraan atau prediksi permintaan dan kuantitas sebenarnya yang tersedia dalam persediaan (Cahyati, 2019).

$$Tracking\ Signal = \frac{RSFE}{MAD} \quad (4)$$

Dimana,

$$RSFE = \sum (a_t - f_t) \quad (5)$$

$$MAD = \frac{\sum |a_t - f_t|}{n} \quad (6)$$

- $a_t$  : Nilai aktual pada periode  $t$
- $f_t$  : Nilai peramalan pada periode  $t$
- $n$  : Banyaknya data

9. Membandingkan nilai MSE dan MAPE terkecil dari arsitektur yang dibuat.
10. Melakukan peramalan dari bulan Januari 2023 sampai dengan Juni 2023 dari arsitektur terbaik masing-masing material.
11. Menghitung nilai ROP dan *safety stock* dengan menggunakan rumus dibawah ini (Bhavsar & Sinha, 2019):

$$ROP = (d \times l) + SS \quad (7)$$

Apabila adanya ketidakpastian permintaan dan ketidakpastian *lead time* (Pujawan & Mahendrawati, 2017) maka nilai *safety stock* dinyatakan dalam rumus:

$$SS = Z \times S_{dl} \quad (8)$$

$$S_{dl} = \sqrt{(d^2 \times S_l^2) + (l \times S_d^2)} \quad (9)$$

Dimana,

ROP : *Reorder Point*

$d$  : permintaan rata-rata

$l$  : *lead time*

SS : *Safety stock*

$S_{dl}$  : Standar deviasi permintaan selama *lead time*

$S_d$  : Standar deviasi permintaan

$S_l$  : Standar deviasi *lead time*

$Z$  : Nilai *service level*

Berikut adalah algoritma *Feedforward Backpropagation Neural Network* (Tomia et al., 2017):

Langkah 0, Bobot-bobot diinisialisasi.

Langkah 1, Selama syarat berhenti belum terpenuhi, lakukan langkah 2 hingga 9.

Langkah 2, Untuk setiap pasangan pelatihan, jalankan langkah 3 hingga 8.

*Feed Forward*:

Langkah 3, Setiap unit input ( $x_i, i = 1, \dots, n$ ) menerima sinyal *input*  $x_i$  dan diteruskan ke unit-unit tersembunyi.

Langkah 4, Setiap unit tersembunyi ( $z_j, j = 1, \dots, p$ ) menjumlahkan sinyal masukan berbobot.

$$z_{net_j} = v_{jo} + \sum_i^n x_i v_{ji} \quad (10)$$

dengan mengaplikasikan fungsi aktivasi hitung:

$$z_j = f(z_{net_j}) \quad (11)$$

Dan memberi sinyal ke unit *output*.

Langkah 5, Masing-masing unit *output* ( $y_k, k = 1, \dots, m$ ) menjumlahkan sinyal *input* berbobot.

$$y_{net_k} = w_{ko} + \sum_j^p z_j w_{kj} \quad (12)$$

dengan mengaplikasikan fungsi aktivasi hitung:

$$y_k = f(y_{net_k}) \quad (13)$$

*Backpropagation error*:

Langkah 6, Masing-masing unit *output* ( $y_k, k = 1, \dots, m$ ) mendapat pola target berkaitan dengan pola pelatihan *input*.

Hitung *error*:

$$\delta_k = (t_k - y_k) f'(y_{net_k}) \quad (14)$$

Hitung perbaikan bobot:

$$\Delta w_{kj} = \alpha \delta_k z_j \quad (15)$$

Langkah 7, Masing-masing unit tersembunyi ( $z_j, j = 1, \dots, p$ ) delta masukannya dijumlahkan dari unit-unit di lapisan yang terletak atasnya.

$$\delta_{net_j} = \sum_k^m \delta_k w_{kj} \quad (16)$$

Hitung *error*:

$$\delta_j = \delta_{net_j} f'(z_{net_j}) \quad (17)$$

Hitung perbaikan bobot:

$$\Delta v_{ji} = \alpha \delta_j x_i \quad (18)$$

Pembaharuan bobot dan bias:

Langkah 8, Masing-masing unit *output* ( $y_k, k = 1, \dots, m$ ) melakukan pembaharuan bobot-bobot dan bias ( $j = 0, 1, \dots, p$ ).

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} \quad (19)$$

Masing-masing unit tersembunyi ( $z_j, j = 1, \dots, p$ ) meng-*update* bobot dan *threshold*-nya ( $i = 0, 1, \dots, n$ ).

$$v_{ji}(\text{baru}) = v_{ji}(\text{lama}) + \Delta v_{ji} \quad (20)$$

Langkah 9, Tes syarat berhenti.

Keterangan

- $x_1 \dots x_n$  : *input*
- $y_1 \dots y_n$  : *output*
- $z_1 \dots z_n$  : nilai *hidden layer*
- $v_{ji}$  : bobot antara lapisan *input* dan lapisan *hidden*
- $v_{j0}$  : bias antara lapisan *input* dan lapisan *hidden*
- $w_{kj}$  : bobot antara lapisan *hidden* dan lapisan *output*
- $w_{k0}$  : bias antara lapisan *hidden* dan lapisan *output*
- $\delta$  : informasi *error*
- $\alpha$  : kecepatan atau laju belajar


### III. HASIL DAN PEMBAHASAN

#### 3.1 Karakteristik Data


Untuk mengetahui karakteristik data dapat dilakukan dengan statistika deskriptif. Data yang dikumpulkan adalah data permintaan material periode Januari 2018 sampai dengan Desember 2022 di seluruh site PT XYZ. Berikut ini adalah statistika deskriptif untuk material *acetylene* dan *oxygen*.

Tabel 1. Statistik deskriptif

	<i>Acetylene</i>	<i>Oxygen</i>
<b>Mean</b>	29,22	48,27
<b>Median</b>	30	50.5
<b>Mode</b>	9	16
<b>Std Deviation</b>	15,297	26,061
<b>Sample Variance</b>	234,003	679,182
<b>Kurtosis</b>	-0,940	-1,096
<b>Skewness</b>	-0,043	-0,014
<b>Minimum</b>	5	5
<b>Maximum</b>	63	102
<b>Sum</b>	1753	2896



Gambar 1. Grafik permintaan material tabung *acetylene*



Gambar 2. Grafik permintaan material tabung oxygen

Berdasarkan tabel 1 perbandingan rata-rata permintaan material *consumable* pekerjaan panas dengan nilai standar deviasi memiliki perbedaan yang besar dengan kata lain sampel data memiliki keragaman yang besar pula. Dari grafik permintaan material tabung *acetylene* dan *oxygen* pada Gambar 1 dan 2, dapat dilihat bahwa terdapat tren kenaikan dari bulan Januari 2018 hingga Desember 2022, namun secara visual tidak terdapat pola musiman pada permintaan kedua material tersebut dan juga secara visual data tidak stasioner.

### 3.2 Preprocessing Data

Pada tahap ini data asli dilakukan normalisasi sesuai dengan persamaan 1, setelah itu akan dilakukan penentuan data masukan dan data keluaran untuk masing-masing proses *training* seperti pada tabel 1 dan proses *testing* seperti pada tabel 2.

Tabel 2. Data masukan dan keluaran *training*

No.	Data Masukan ( $x_1...x_{12}$ )	Data Keluaran ( $y$ )
1.	Data ke-1 s.d. ke-12	Data ke-13
2.	Data ke-2 s.d. ke-13	Data ke-14
3.	Data ke-3 s.d. ke-14	Data ke-15
.	.	.
.	.	.
36.	Data ke-36 s.d. ke-47	Data ke-48

Tabel 3. Data masukan dan keluaran *testing*

No.	Data Masukan ( $x_1...x_{12}$ )	Data Keluaran ( $y$ )
1.	Data ke-37 s.d. ke-48	Data ke-49
2.	Data ke-38 s.d. ke-49	Data ke-50
3.	Data ke-39 s.d. ke-50	Data ke-51
.	.	.
.	.	.
12.	Data ke-48 s.d. ke-59	Data ke-60

Pada tabel 2 merupakan proses pembentukan data pelatihan periode Januari 2018 - Desember 2021 dengan menentukan data *predictor* atau data masukan ( $x_1...x_{12}$ ) yang berasal dari data permintaan bulan Januari 2018 sampai dengan data bulan Desember 2018, kemudian data keluaran atau data targetnya adalah data bulan Januari 2019, selanjutnya data masukan berasal dari data permintaan Februari 2018 sampai dengan Januari 2019 dengan data keluaran atau data target adalah bulan Februari 2019, demikian seterusnya hingga data keluaran mencapai data bulan Desember 2021. Untuk data pengujian menggunakan data periode Januari 2022 - Desember 2022, kemudian juga dilakukan proses yang sama dimulai dari Januari 2021 sampai dengan Desember 2021 sebagai data masukan dan data bulan Januari 2022 sebagai data target (Tabel 3).

Maka dari itu jumlah input pada pembentukan model ANN peramalan ini adalah sebanyak 12 dan data output adalah sebanyak 1.

### 3.3 Evaluasi Model

Setelah menentukan parameter yang dijadikan input dalam model ANN, maka selanjutnya dilakukan proses pelatihan dan pengujian. Pada proses pelatihan dan pengujian ini akan dilihat nilai MSE dan MAPE dari beberapa percobaan jaringan arsitektur pada masing-masing material. Nilai MSE dan MAPE terkecil akan dijadikan model arsitektur terbaik dalam peramalan metode ANN.

Tabel 4. Evaluasi arsitektur pada tabung *acetylene*

Arsitektur	Train		Test	
	MSE	MAPE	MSE	MAPE
12-1-1	0,0233	38,21	130,63	18,99
<b>12-2-1</b>	<b>0,0184</b>	<b>31,09</b>	<b>74,79</b>	<b>18,37</b>
12-3-1	0,0202	34,92	149,07	29,23
12-4-1	0,0197	33,89	102,77	20,46
12-5-1	0,0210	35,44	162,19	24,00

Tabel 5. Evaluasi arsitektur pada tabung *oxygen*

Arsitektur	Train		Test	
	MSE	MAPE	MSE	MAPE
12-1-1	0,0158	22,86	226,38	19,64
12-2-1	0,0142	20,85	293,46	22,25
12-3-1	0,0155	21,21	243,98	19,77
<b>12-4-1</b>	<b>0,0123</b>	<b>20,68</b>	<b>224,11</b>	<b>16,51</b>
12-5-1	0,0154	21,55	226,28	18,14

Dari tabel 4 dapat diketahui bahwa arsitektur terbaik pada peramalan tabung *acetylene* adalah pada konfigurasi 12-2-1 dengan MSE 0,0184 dan MAPE 31,09% pada evaluasi pelatihan, dan pada saat evaluasi pengujian nilai MSE dan MAPE yang dihasilkan adalah 74,79 dan 18,37%. Pada tabel 5 untuk peramalan tabung *oxygen* arsitektur terbaik pada konfigurasi 12-4-1 dengan MSE 0,0123 dan MAPE 20,68% pada evaluasi pelatihan dan pada saat evaluasi pengujian nilai MSE dan MAPE yang dihasilkan adalah 224,11 dan 16,51%.

Untuk mengetahui peramalan yang dihasilkan apakah lebih besar dibandingkan permintaan aktual atau pun sebaliknya, maka akan dilakukan analisis *tracking signal* pada masing-masing material pekerjaan panas. Berikut adalah hasil perhitungan *tracking signal*.

Tabel 6. *Tracking signal* hasil peramalan *acetylene*

Bulan	$a_t$	$f_t$	RSFE	MAD	<i>Tracking Signal</i>
Jan-22	24	43,24	-19,24	19,24	-1
Feb-22	38	44,26	-25,5	22,37	-1,14
Mar-22	31	41,05	-35,55	26,76	-1,33
Apr-22	40	42,88	-38,43	29,68	-1,29
Mei-22	63	54,15	-29,58	29,66	-1
Jun-22	42	44,56	-32,14	30,07	-1,07
Jul-22	47	46,4	-31,53	30,28	-1,04
Ags-22	38	44,84	-38,37	31,29	-1,23
Sept-22	41	39,72	-37,09	31,94	-1,16
Okt-22	37	38,68	-38,77	32,62	-1,19
Nov-22	40	44,58	-43,35	33,59	-1,29
Des-22	58	43,12	-28,47	33,17	-0,86

Tabel 7. *Tracking signal* hasil peramalan *oxygen*

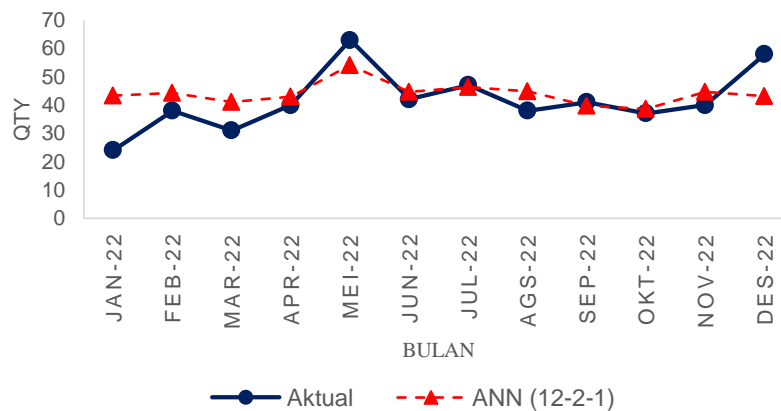
Bulan	$a_t$	$f_t$	RSFE	MAD	<i>Tracking Signal</i>
Jan-22	40	67,71	-27,71	27,71	-1
Feb-22	52	53,63	-29,34	28,52	-1,03
Mar-22	51	61,24	-39,58	32,21	-1,23

Tabel 7. *Tracking signal* hasil peramalan *oxygen* (Lanjutan)


Bulan	$a_t$	$f_t$	RSFE	MAD	<i>Tracking Signal</i>
Apr-22	55	48,5	-33,08	32,42	-1,02
Mei-22	89	56,56	-0,63	26,07	-0,02
Jun-22	61	62,9	-2,53	22,14	-0,11
Jul-22	75	68,88	3,59	19,49	0,18
Ags-22	68	66,93	4,66	17,64	0,26
Sept-22	70	73,3	1,36	15,83	0,09
Okt-22	65	68,7	-2,34	14,48	-0,16
Nov-22	72	66,59	3,07	13,44	0,23
Des-22	94	69,04	28,03	14,66	1,91

Pada tabel 6 hasil *tracking signal* pada material *acetylene* menunjukkan hasil minus dari periode Januari 2022 sampai dengan Desember 2022, hal ini mengindikasikan bahwa aktual permintaan lebih kecil dibanding dengan peramalan. Akumulasi *tracking signal* dapat dilihat dari periode Desember 2022 yang menghasilkan nilai -0,86 pada peramalan periode Januari 2022 sampai dengan Desember 2022, pada *tracking signal* material *acetylene* menunjukkan bahwa peramalan lebih besar daripada aktual. Pada hasil *tracking signal* untuk material *oxygen* (tabel 7) menunjukkan akumulasi *tracking signal* sebesar 1,91 yang berarti data aktual lebih besar daripada peramalan.

Untuk melihat hasil prediksi yang dihasilkan oleh model ANN pada masing-masing peramalan material dapat dilihat melalui grafik dibawah.



Gambar 3. Grafik perbandingan data testing dengan hasil prediksi material tabung *acetylene*



Gambar 4. Grafik perbandingan data testing dengan hasil prediksi material tabung *oxygen*



Pada gambar 3 adalah perbandingan grafik data aktual atau data *testing* untuk material tabung *acetylene* dapat dilihat bahwa model dapat memprediksi data aktual namun di bulan-bulan tertentu seperti Januari, Maret, dan Desember 2022 meleset dari data aktual. Pada gambar 4 merupakan hasil perbandingan grafik data aktual atau data *testing* untuk material tabung *oxygen*, pada peramalan material ini pada bulan Januari, Mei, dan Desember 2022 dapat dilihat model meleset untuk memprediksi data aktual.

### 3.4 Peramalan, Penentuan ROP dan SS

Untuk menganalisis kebutuhan stok material, yakni nilai ROP dan SS, maka akan menggunakan data hasil peramalan pada periode Januari 2023 sampai dengan Desember 2023, berikut adalah hasil peramalan material dengan menggunakan metode ANN.

Tabel 8. Peramalan bulan Januari - Desember 2023

Bulan	Acetylene	Oxygen
Januari-2023	44,79	68,45
Februari-2023	48,77	66,14
Maret-2023	45,05	66
April-2023	46,06	64,93
Mei-2023	46,9	63,02
Juni-2023	44,59	63,43
Juli-2023	44,15	64,38
Agustus-2023	44,95	63,31
September-2023	44,39	64,92
Oktober-2023	44,74	65,33
November-2023	44,13	65,37
Desember-2023	46,08	66,06
<b>Mean</b>	<b>45,38</b>	<b>65,11</b>
<b>Standar Deviasi</b>	<b>1,36</b>	<b>1,51</b>

Pada tabel 8 rata-rata permintaan ( $d$ ) dan standar deviasi permintaan ( $S_d$ ) sudah dapat diketahui. Untuk rata-rata *lead time* ( $l$ ) dan standar deviasi *lead time* ( $S_l$ ) didapatkan dari tanggal dibuatnya *purchase order* (PO) dengan tanggal kedatangan material seperti pada tabel berikut ini.

Tabel 9. *Lead time* material tabung *acetylene*

Tgl PO	Tgl Datang	Lead Time (Hari)
26-Jan-22	12-Feb-22	17
02-Mar-22	18-Mar-22	16
07-May-22	17-May-22	10
23-May-22	24-May-22	1
30-Jun-22	30-Jul-22	30
26-Jul-22	28-Jul-22	2
02-Sep-22	06-Sep-22	4
10-Nov-22	12-Nov-22	2
10-Nov-22	14-Nov-22	4
	<b>Mean</b>	<b>9,56</b> Hari
		<b>0,32</b> Bulan
	<b>Standar Deviasi</b>	<b>9,77</b> Hari
		<b>0,33</b> Bulan

Tabel 10. *Lead time* material tabung *oxygen*

Tgl PO	Tgl Datang	Lead Time (Hari)
26-Jan-22	7-Mar-22	40
17-Feb-22	18-Mar-22	29
30-Jun-22	25-Sep-22	87
7-May-22	17-May-22	10
23-May-22	26-May-22	3
26-Jul-22	28-Jul-22	2
2-Sep-22	26-Nov-22	85
10-Nov-22	12-Nov-22	2

Tabel 10. *Lead time material tabung oxygen* ) (Lanjutan)

Tgl PO	Tgl Datang	Lead Time (Hari)	
10-Nov-22	15-Nov-22	5	
19-Nov-22	12-Jan-23	54	
16-Nov-22	17-Nov-22	1	
15-Dec-22	1-Feb-23	48	
<b>Mean</b>		<b>30,50</b>	Hari
		<b>1,02</b>	Bulan
<b>Standar Deviasi</b>		<b>32,24</b>	Hari
		<b>1,07</b>	Bulan

Pada tabel 9 dan 10 dapat diketahui rata-rata *lead time* ( $l$ ) dan standar deviasi *lead time* ( $S_l$ ) pada masing-masing material. Kemudian dengan menggunakan persamaan 8 dan 9 akan ditentukan nilai SS dan kemudian menggunakan persamaan 7 untuk menentukan nilai ROP. Dengan menggunakan nilai *service level* 95% ( $Z=1.65$ ) didapatkan nilai SS dan ROP sebagai berikut.

Tabel 11. Hasil perhitungan *safety stock* dan ROP

	<i>Acetylene</i>	<i>Oxygen</i>
$d$	45,38	65,11
$l$	0,33	1,02
$S_d$	1,36	1,51
$S_l$	0,32	1,07
<b>SS</b>	<b>24</b>	<b>115</b>
<b>ROP</b>	<b>39</b>	<b>181</b>

Berdasarkan tabel 11 maka dapat diketahui bahwa pada material *acetylene*, jumlah stok pengaman atau *safety stock* adalah sebanyak 24 tabung, dan jumlah ROP adalah sebanyak 39 tabung, nilai ROP pada material *acetylene* dapat mengakomodir *lead time* dengan rata-rata selama 9,56 hari (10 hari). Pada material tabung *oxygen*, jumlah stok pengaman adalah sebanyak 115 tabung, dan jumlah ROP adalah sebanyak 181 tabung untuk mengakomodir *lead time* dengan rata-rata selama 30,5 hari (31 hari).

#### IV. SIMPULAN

Peramalan material *consumable* tabung *acetylene* dan *oxygen* telah dilakukan untuk mencegah material *stock out*. Penggunaan metode ANN dalam peramalan tabung *acetylene* menghasilkan arsitektur terbaik yaitu 12-2-1 dengan nilai MSE 0,0184 dan MAPE 31,09% pada evaluasi pelatihan, dan pada saat evaluasi pengujian nilai MSE dan MAPE yang dihasilkan adalah 74,79 dan 18,37%. Pada peramalan tabung *oxygen* arsitektur terbaik pada konfigurasi 12-4-1 dengan MSE 0,0123 dan MAPE 20,68% pada evaluasi pelatihan dan pada saat evaluasi pengujian nilai MSE dan MAPE yang dihasilkan adalah 224,11 dan 16,51%. *Tracking signal* pada evaluasi model menunjukkan bahwa akumulasi peramalan pada *acetylene* bernilai -0,86 yang berarti nilai aktual lebih kecil dibandingkan dengan nilai peramalan. Pada *tracking signal* tabung *oxygen* mempunyai nilai akumulasi nilai 1,91 yang berarti nilai aktual lebih besar dibandingkan dengan nilai peramalan. Nilai ROP pada tabung *acetylene* berjumlah 39 pcs untuk mengakomodir *lead time* rata-rata selama 10 hari. *Safety stock* tabung *acetylene* berjumlah 24 pcs. Pada material tabung *oxygen* nilai ROP berjumlah 181 pcs untuk mengakomodir *lead time* rata-rata selama 30 hari dan memiliki nilai *safety stock* sebesar 115 pcs.

#### DAFTAR PUSTAKA

- Ali Salamai, A., Abdulrahman Ageeli, A., & M. El-kenawy, E.-S. (2022). Forecasting E-Commerce Adoption Based on Bidirectional Recurrent Neural Networks. *Computers, Materials & Continua*, 70(3), 5091–5106. <https://doi.org/10.32604/cmc.2022.021268>
- Bhavsar, V. R., & Sinha, B. (2019). SELECTION OF REORDER POINT WHEN DEMAND IS VARIABLE AND ALSO LEAD TIME IS VARIABLE WITH DIFFERENT SIGNIFICANCE LEVEL TO DEMAND DEVIATION & LEAD DEVIATION. *INTERNATIONAL JOURNAL OF MANAGEMENT*, 10(6). <https://doi.org/10.34218/IJM.10.6.2019.022>
- Cahyati, A. N. (2019). *Penentuan Minimum Stock Consumable Spare Part Menggunakan Forecast dan ROP Pada PT. SMART Tbk Surabaya*.
- Dristiana, F., & Sukmono, T. (2015). PENGENDALIAN PERSEDIAAN BAHAN BAKU OBAT DENGAN MENGGUNAKAN METODE EOQ PROBABILISTIK BERDASARKAN PERAMALAN

- EXPONENTIAL SMOOTHING PADA PT. XYZ. *SPEKTRUM INDUSTRI*, 13(2), 181. <https://doi.org/10.12928/si.v13i2.2695>
- Gutierrez, R. S., Solis, A. O., & Mukhopadhyay, S. (2008). Lumpy demand forecasting using neural networks. *International Journal of Production Economics*, 111(2), 409–420. <https://doi.org/10.1016/j.ijpe.2007.01.007>
- Hu, Y.-C. (2020). Constructing grey prediction models using grey relational analysis and neural networks for magnesium material demand forecasting. *Applied Soft Computing*, 93, 106398. <https://doi.org/10.1016/j.asoc.2020.106398>
- İfraz, M., Aktepe, A., Ersöz, S., & Çetinyokuş, T. (2023). Demand forecasting of spare parts with regression and machine learning methods: Application in a bus fleet. *Journal of Engineering Research*, 11(2), 100057. <https://doi.org/10.1016/j.jer.2023.100057>
- M, I. N., Jono, J., & Mindhayani, I. (2020). Perencanaan Kebutuhan Bahan Baku Pada Produksi Roti Varian Moka Studi kasus di CV. Roti bangkit. *Jurnal Rekayasa Industri (JRI)*, 2(2), 78–85. <https://doi.org/10.37631/jri.v2i2.181>
- Pujawan & Mahendrawati. (2017). *Supply Chain Management*. ANDI.
- Rathipriya, R., Abdul Rahman, A. A., Dhamodharavadhani, S., Meero, A., & Yoganandan, G. (2023). Demand forecasting model for time-series pharmaceutical data using shallow and deep neural network model. *Neural Computing and Applications*, 35(2), 1945–1957. <https://doi.org/10.1007/s00521-022-07889-9>
- Rodrigues, L. R., & Yoneyama, T. (2020). A spare parts inventory control model based on Prognostics and Health monitoring data under a fill rate constraint. *Computers & Industrial Engineering*, 148, 106724. <https://doi.org/10.1016/j.cie.2020.106724>
- Shi, J. (2022). Application of the model combining demand forecasting and inventory decision in feature based newsvendor problem. *Computers & Industrial Engineering*, 173, 108709. <https://doi.org/10.1016/j.cie.2022.108709>
- Susetyo, J., Asih, E. W., & Raharjo, H. (2020). Optimalisasi Jumlah Produksi Menggunakan Fuzzy Inference System Metode Min-Max. *Jurnal Rekayasa Industri (JRI)*, 2(1), 8–14. <https://doi.org/10.37631/jri.v2i1.126>
- Tomia, S., Leleury, Z. A., & Aulele, S. N. (2017). PERBANDINGAN METODE JARINGAN SARAF TIRUAN BACKPROPAGATION DAN LEARNING VECTOR QUANTIZATION DALAM DETEKSI HAMA PENGEREK BATANG. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 11(1), 13–26. <https://doi.org/10.30598/barekengvol11iss1pp13-26>
- Zhu, S., Van Jaarsveld, W., & Dekker, R. (2022). Critical project planning and spare parts inventory management in shutdown maintenance. *Reliability Engineering & System Safety*, 219, 108197. <https://doi.org/10.1016/j.ress.2021.108197>