

Forecasting Product Sales of Crackers Using Artificial Neural Network Method and Double Exponential Smoothing Holts [Peramalan Penjualan Produk Kerupuk Pasir Menggunakan Metode Artificial Neural Network dan Double Exponential Smoothing Holts]

Safia Meilia Sari¹⁾, Indah Apriliana Sari Wulandari^{*2)}

¹⁾*Program Studi Teknik Industri, Universitas Muhammadiyah Sidoarjo, Indonesia*

²⁾*Program Studi Teknik Industri, Universitas Muhammadiyah Sidoarjo, Indonesia*

*Email Penulis Korespondensi: indahapriliana@umsida.ac.id

Abstract. UD. XYZ is a producer of sand crackers with fluctuating sales levels the highest fluctuating value of 37% in March 2020. As a result, there was a buildup of 4197 kg raw materials for four years and a shortage of raw materials in August 2021. This research aims to assist companies in predicting sales in the coming period. by proposing the best sales forecasting method as an improvement in anticipating raw material control. The method used in this research is an artificial neural network and double exponential smoothing holts. The results showed that the accuracy of sales forecasting on the artificial neural network has the best accuracy rate of 0.118 compared to double exponential smoothing holts of 11.639. The conclusion the research is proposing improvements to sales prediction methods to anticipate declining sales the next period as well as improvements to raw material ordering planning experience extreme excesses and shortages.

Keywords – Prediction; Artificial Neural Network; Root Mean Square Error; Sand Cracker Manufacture

Abstrak. UD. XYZ merupakan produsen kerupuk pasir dengan tingkat penjualan fluktuatif dengan nilai fluktuatif tertinggi sebesar 37% bulan Maret 2020. Akibatnya terjadi penumpukan bahan baku sebanyak 4197 kg selama empat tahun serta kekurangan bahan baku pada Agustus 2021. Penelitian ini bertujuan membantu perusahaan dalam memprediksi penjualan pada periode mendatang dengan mengusulkan metode peramalan penjualan terbaik sebagai perbaikan dalam mengantisipasi pengendalian bahan baku. Metode yang digunakan penelitian ini adalah *artificial neural network* dan *double exponential smoothing holts*. Hasil penelitian diperoleh akurasi peramalan penjualan pada *artificial neural network* memiliki tingkat akurasi paling baik yaitu 0,118 dibandingkan *double exponential smoothing holts* sebesar 11,639. Kesimpulan dari penelitian yaitu mengusulkan perbaikan metode prediksi penjualan untuk mengantisipasi penjualan yang menurun pada periode selanjutnya serta perbaikan terhadap perencanaan pemesanan bahan baku agar tidak mengalami kelebihan dan kekurangan secara ekstrim.

Kata Kunci – Peramalan; *Artificial Neural Network*; *Double Exponential Smoothing Holts*; *Manufaktur Kerupuk Pasir*

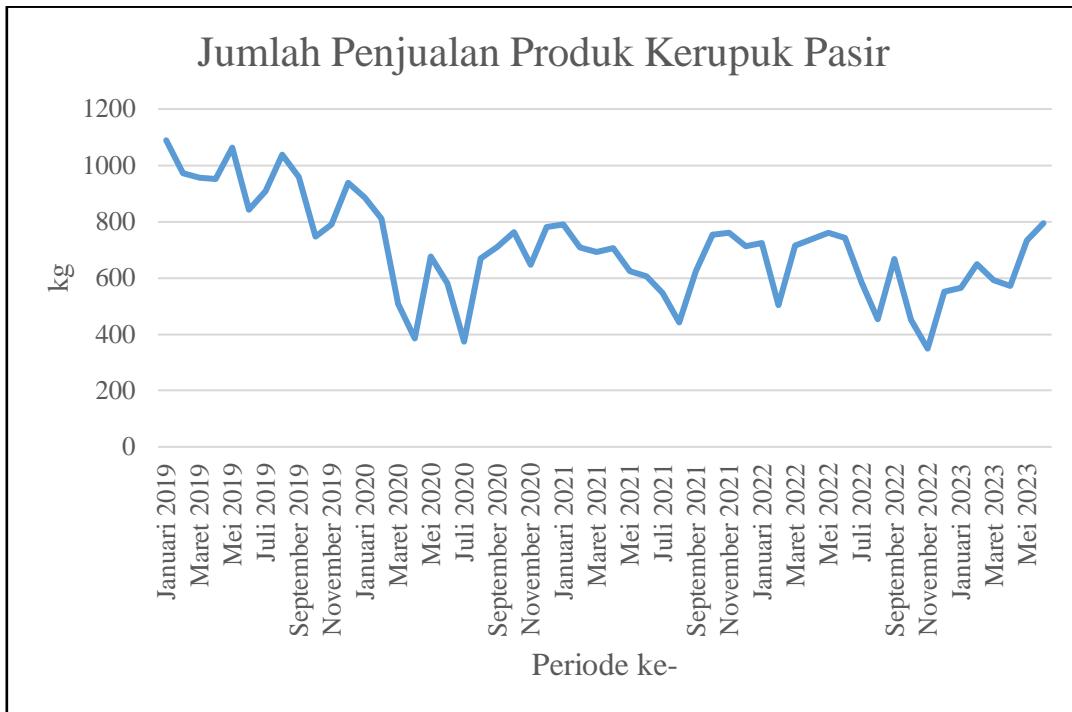
I. PENDAHULUAN

Perkembangan industri di Indonesia dinilai mengalami perubahan yang pesat dalam seluruh sektor. Hal tersebut menjadi desakan bagi perusahaan untuk menciptakan terobosan baru agar dapat bertahan dalam memenuhi kebutuhan konsumen di masa mendatang. Timbulnya permasalahan dalam mengestimasi kebutuhan mendatang merupakan faktor penting dalam memberikan kepuasan konsumen. Dengan adanya strategi peramalan menjadi salah satu pilihan terbaik untuk memperkirakan kebutuhan di masa mendatang. Dengan melakukan peramalan maka perusahaan dapat menghitungkan jumlah permintaan dan penjualan produk dengan optimal. Sehingga peramalan menjadi faktor penting sebagai pemenuhan pesanan yang dibutuhkan konsumen serta pengendalian produksi bagi perusahaan dan juga dapat meminimalisir biaya produksi yang berlebihan [1].

Persediaan bahan baku yang tidak optimal di sektor industri merupakan salah satu permasalahan yang sering terjadi akibat tidak adanya prediksi. Hal tersebut menyebabkan terhambatnya proses produksi mulai dari pemesanan bahan baku yang dijadwalkan ulang, liburnya kegiatan produksi karena kekurangan stok bahan baku, serta pengeluaran biaya tambahan untuk memenuhi kebutuhan produksi yang mengalami kekurangan stok dan penanggulangan penumpukan bahan baku yang tidak layak pakai [2].

Permasalahan persediaan bahan baku juga terjadi pada UD. XYZ yang merupakan salah satu usaha mikro kecil menengah bergerak di bidang industri dengan produksi kerupuk pasir. Permintaan produk kerupuk pasir mengalami kondisi yang fluktuatif selama empat tahun terakhir dimulai dari tahun 2019 dan semakin memperparah pada masa *lockdown covid-19* dengan nilai fluktuasi terbesar pada bulan Maret 2020 sebesar 37% dari bulan sebelumnya. Kondisi tersebut mengakibatkan banyak kerugian produksi mulai dari kegiatan produksi yang diliburkan selama 20 hari dengan

jangka pada bulan Maret 2020 sampai dengan April 2020. Dan tingkat penjualan yang cenderung rendah mengakibatkan terjadinya penumpukan bahan baku sebanyak 4197 kg selama empat tahun berturut-turut yaitu tahun 2019 sebanyak 142 kg, tahun 2020 sebanyak 3552 kg, tahun 2021 sebanyak 59 kg, dan tahun 2022 sebanyak 444 kg. Selain itu terjadi kekurangan persediaan bahan baku pada bulan Agustus 2021 sebanyak 16 kg. Hal ini terkait fenomena yang mendasari penjualan mengalami fluktuatif sehingga mengakibatkan terhambatnya sistem produksi serta kerugian pada perusahaan.



Gambar 1. Grafik Penjualan Produk Kerupuk Pasir.

Dari permasalahan tersebut dilakukan penyelesaian dengan melakukan peramalan penjualan sebagai optimalisasi persediaan bahan baku. Sehingga tujuan penelitian ini melakukan peramalan penjualan dengan metode *artificial neural network* dan *double exponential smoothing holts* sebagai pilihan terbaik untuk membandingkan hasil peramalan paling optimal dengan tingkat akurasi paling efektif dan tingkat kesalahan yang terendah. Perbandingan tersebut akan digunakan sebagai pengambilan keputusan dalam meramalkan penjualan produk sebagai pembenahan sistematis persediaan bahan baku.

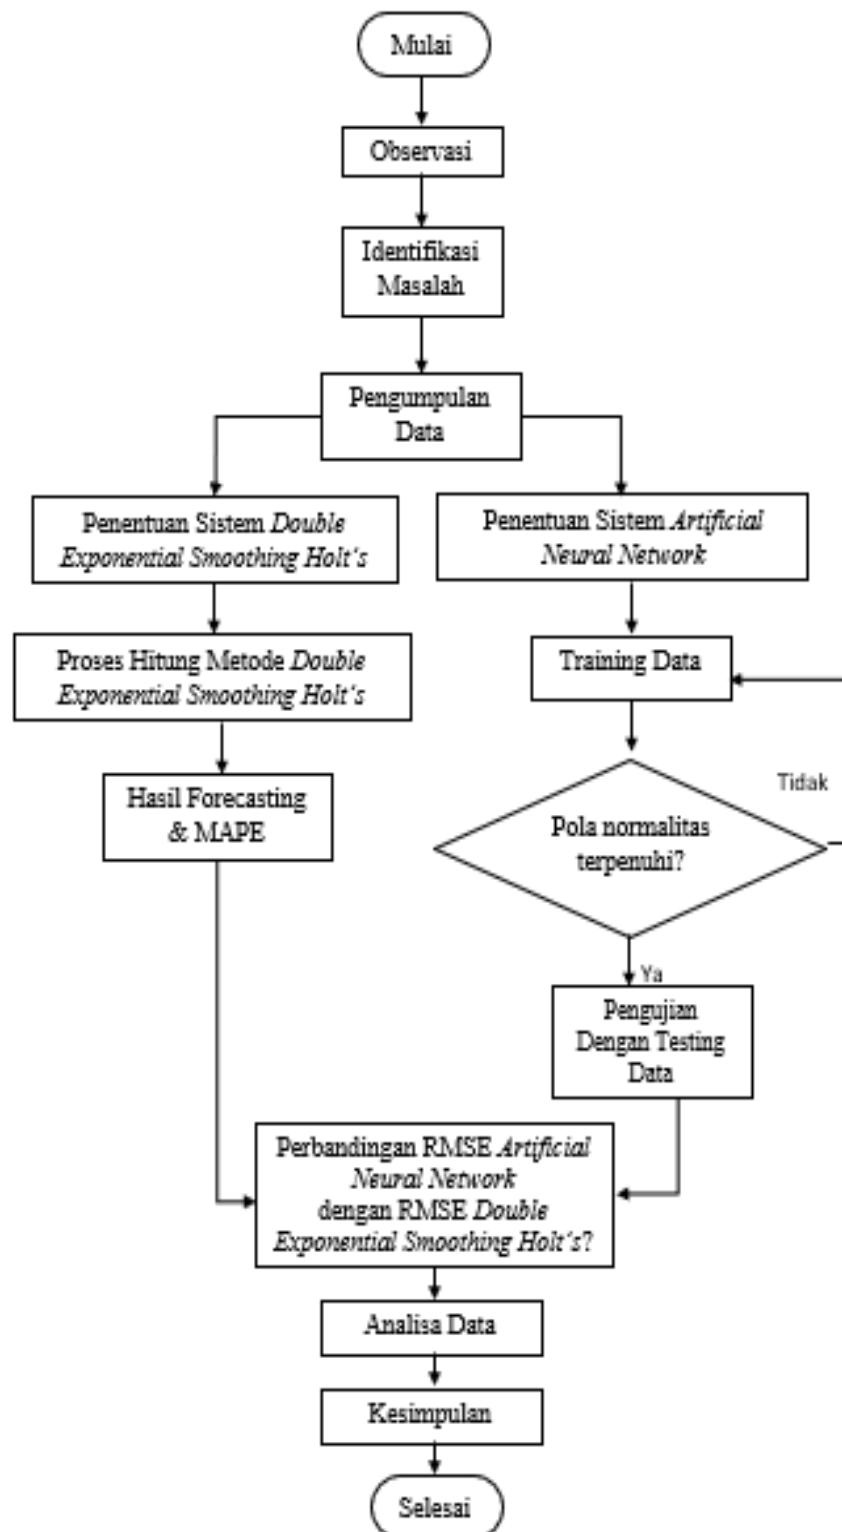
Penelitian ini dilakukan untuk menghasilkan peramalan jumlah penjualan produk kerupuk pasir pada periode mendatang serta membandingkan metode yang paling optimal digunakan dalam penyelesaian masalah pada UD. XYZ antara lain metode *artificial neural network* dan metode *double exponential smoothing holts*. Sekaligus menemukan bentuk arsitektur *artificial neural network* dalam menghitung peramalan penjualan kerupuk pasir. Dari hasil peramalan yang telah dibandingkan akan digunakan sebagai usulan perbaikan pada sistem perencanaan perhitungan data penjualan di UD. XYZ untuk membantu dalam mengatasi kondisi persediaan bahan baku yang tidak optimal.

Berdasarkan penelitian yang dilakukan oleh Tantyo dengan judul Perbandingan Antara Metode *Holts* Dan *Backpropagation* Pada Model Peramalan Penjualan memperoleh hasil akurasi prediksi paling efektif pada metode *backpropagation* dengan hasil *error* terkecil sebesar 0,00057201 [2]. Dan penelitian yang dilakukan oleh Dzulfikar dengan judul Implementasi Peramalan Penjualan Produk di PT Prima Per Tradea Utama Menggunakan Metode *Artificial Neural Network* yaitu berhasil diimplementasikan dengan rata-rata akurasi peramalan sebesar 97% dengan nilai MAPE yaitu 3,35% [3].

II. METODE

Penelitian ini dilakukan dengan pendekatan kuantitatif dan kualitatif. Metode kuantitatif digunakan untuk menyelesaikan permasalahan dengan membandingkan metode *Artificial Neural Network* (ANN) dan *Double Exponential Smoothing Holts*. Sedangkan metode kualitatif merupakan pengumpulan data melalui observasi mengamati tingkat penjualan selama 4 tahun 6 bulan serta sistematis persediaan bahan baku pada UD. XYZ. Dengan

menggunakan data yang telah dikumpulkan selama observasi sebagai *input* adalah data penjualan produk kerupuk pasir dengan jangka waktu yang di teliti selama 4 tahun 6 bulan mulai dari bulan Januari 2019 sampai dengan Juni 2023. Adapun hasil *flowchart* dari penelitian terlihat pada gambar 2.



Gambar 2. Alur Proses Penelitian.

Keterangan :

Maksimum iterasi	= jumlah maksimum iterasi yaitu 500
RMSE ANN	= nilai <i>root mean square error artificial neural network</i>
RMSE Holts	= nilai <i>root mean square error holts</i>

Peramalan merupakan ilmu yang memperkirakan momen pada masa mendatang dengan mengaitkan data historis sebagai interpretasi model pendekatan yang sistematis dalam upaya sebagai pengambilan keputusan yang tepat dalam jangka panjang [4]. *Forecasting* merupakan teknik yang memperkirakan pengaruh kondisi dan situasi yang berlaku terhadap perkembangan masa mendatang. *Forecasting* dapat dinyatakan dengan suatu nilai tertentu dari sebuah kejadian pada periode yang akan diimplementasikan pada periode selanjutnya melalui variabel pendekatan tertentu. Hal tersebut menjadi asumsi bahwa sebuah prediksi membuktikan kondisi masa lalu tidak jauh berbeda dengan masa depan [5]. Peramalan tidak dapat dijadikan sebagai kondisi yang bersifat permanen Akan tetapi peramalan dapat dijadikan sebagai evaluasi sistem untuk kebutuhan masa mendatang. Hal tersebut terjadi karena peramalan memiliki keterkaitan terhadap *trend moment* setiap periodenya. Tujuan peramalan selain untuk memperkirakan kejadian masa mendatang antara lain, membantu perencanaan jangka panjang yang efektif, alat bantu dalam proses pengambilan keputusan yang tepat, metode dalam memprediksi kebutuhan masa mendatang [6].

Data mining adalah ilmu untuk identifikasi banyaknya data dengan menemukan pola dan informasi yang menarik. Proses pencarian pola dilakukan pada persebaran banyaknya data yang tersembunyi berupa *node*. Proses pemilihan data akan dilakukan dengan menggunakan teknologi pengenalan pola, teknik perhitungan statik serta matematik. Dan *output* yang dihasilkan berupa korelasi, pola, dan tren baru [7]. Data mining merupakan sistem yang dapat mengimplementasikan berbagai teknik statistik, kecerdasan buatan, matematik dan *machine learning* untuk membaca dan menemukan informasi yang ditemukan dari data dalam banyaknya data yang terselubung [8]. Manfaat data mining sangat tepat digunakan untuk menganalisa informasi pengetahuan dari banyaknya database. Proses data mining akan menguraikan beberapa data yang tersembunyi dan meninjau hubungan yang tidak terduga dari banyaknya data tersebut [9]. Pada umumnya data mining digunakan untuk menganalisis data dalam jumlah yang besar dengan istilah *big data analytics*. Tugas yang dapat dilakukan oleh data mining yaitu klaster (pengelompokan), klasifikasi, estimasi, asosiasi, dan prediksi. Masing-masing mampu memberikan hasil yang handal dalam pengoperasinya [10].

Penelitian ini akan menggunakan fungsi data mining yaitu *prediction* yang merupakan teknik memperkirakan hasil dengan menunjukkan kejadian masa lalu pada beberapa data dari masa mendatang [11]. Metode data mining yang digunakan adalah *Artificial Neural network* (ANN) merupakan salah satu metode yang memiliki kehandalan dalam fungsi *prediction*.

A. Artificial Neural network (ANN)

Artificial Neural network (ANN) merupakan sistem pengoperasian yang bekerja berdasarkan fungsi jaringan syaraf manusia. Strukturnya memiliki model seperti bentuk syaraf manusia yang saling terhubung dan bekerja menyalurkan sinyal informasi pada seluruh syaraf kerja di sebuah sistem otak manusia [12]. *Artificial Neural network* (ANN) memiliki banyak lapisan yang tersembunyi, lapisan tersebut merupakan kerangka permasalahan yang harus dipecahkan untuk menghasilkan *output*. Dan hasil *output* merupakan solusi dari pemecahan masalah dari banyaknya data tersembunyi. Ada beberapa neuron pada jaringan syaraf tiruan yaitu fungsi aktivasi, fungsi penjumlahan, dan fungsi *output* [13]. Tahapan peramalan *Artificial Neural network* [14] :

1. Transformasi data (*Pre-processing*)

Transformasi data menggunakan *software RapidMiner* dengan *input* data penjualan sebagai data set untuk dapat diolah. Data set akan digunakan sebagai pelatihan pembelajaran model *Artificial Neural network*. Dengan melakukan pembagian sebanyak dua data yaitu data *training* dan data *testing* dengan rasio pembagian masing-masing sebesar 0,7 dan 0,3. Pada data *training* akan digunakan fungsi proses pelatihan data penjualan untuk mendeteksi struktur rancangan model. Sedangkan data *testing* digunakan untuk proses peramalan data penjualan sebagai fungsi dasar *prediction*.

a.) Normalisasi

Normalisasi dilakukan untuk menguji nilai yang dapat mempengaruhi struktur model tidak berjalan lancar. Sebelum dilakukan pelatihan dan pengujian perlu dilakukan normalisasi data penjualan sebagai optimalisasi bentuk data pada jaringan. Normalisasi data aktual harus memiliki nilai rentang (0-1) dan persamaan rumus sebagai berikut:

$$V_{\text{norm}} = \left(\frac{v_i - v_{\min}}{v_{\max} - v_{\min}} \right) \quad (1)$$

Sumber : [15]

b.) Perancangan arsitektur jaringan

Tahap ini membuat model yang dapat dijalankan dengan memasukkan parameter *neural network*. Hasil penentuan parameter dilakukan dari pengujian *windowing* untuk memperoleh struktur yang optimal. Dengan struktur arsitektur jaringan terlihat pada tabel 1.

Tabel 1. Struktur Arsitektur Jaringan

Parameter	Jumlah	Deskripsi
<i>Input Layer</i>	1	<i>Input</i> : Data penjualan produk <i>Windowing</i> : 6 node (5 data atribut, 1 spesial atribut)
<i>Hidden Layer</i>	<i>Trial & Error</i>	<i>Default software RapidMiner</i>
<i>Output Layer</i>	1 Neuron	0,1-0,9
<i>Learning rate</i>	<i>Trial & Error</i>	0,1-0,9
<i>Momentum</i>	<i>Trial & Error</i>	Maksimum 500
<i>Epoch</i>	<i>Trial & Error</i>	<i>Sigmoid</i>
Fungsi Aktivasi	1	

Sumber : [16]

2. Pelatihan

Proses pelatihan menggunakan data *training* dengan struktur model yang sudah dioptimalisasi untuk mengidentifikasi *error* pada jaringan.

3. Pengujian

Data *testing* dilakukan proses *windowing* untuk mengidentifikasi hasil *prediction* dan *performances*.

B. Double Exponential Smoothing Holts

Exponential Smoothing menggunakan bobot dalam mengolah rata-rata pada seluruh observasi peramalan. Dengan nilai bobot yang jauh lebih efektif saat pengamatan menggunakan data yang lebih lampau periodenya [17]. Metode *double exponential smoothing* sederhana digunakan apabila tidak terdapat komponen musiman atau *trend* pada data tersebut. Nilai *error* akan lebih rendah apabila data yang digunakan dalam *range* banyak. Metode *time series* ini memiliki sistem pengujian dengan memasukkan nilai parameter alpha dan beta. Dengan nilai alpha lebih besar daripada beta untuk mengoptimalkan sebuah perhitungan nilai *error* [18]. Metode *double exponential smoothing holts* menggunakan 2 parameter yaitu parameter α sebagai pemulusan *exponential* dan β sebagai pemulus *trend*. Dengan penggunaan kedua parameter memiliki tingkat peramalan yang akurat [19]. Pemulus eksponensial linier *holts* mempunyai nilai parameter yang tidak sama dengan nilai nilai parameter asli untuk pemulus nilai *trend*. Perumusan metode *holts* menggunakan dua parameter sebagai berikut [20] :

Nilai *double exponential smoothing* ditentukan dengan persamaan (2)

$$S_t' = \alpha X_t + (1 - \alpha) (S_{t-1}' + b_{t-1}) \quad (2)$$

Penentuan nilai tren pemulus dapat menggunakan persamaan (3)

$$b_t = \gamma (S_t' - S_{t-1}') + (1 - \gamma) b_{t-1} \quad (3)$$

Penentuan nilai peramalan dapat menggunakan persamaan (4)

$$F_{t+m}' = S_t' + b_t m \quad (4)$$

Sumber : [20]

Keterangan :

S_t' : Hasil peramalan periode ke t

S_{t-1}' : Hasil peramalan periode ke $t-1$

α : Parameter peramalan ($0 < \alpha < 1$)

X_t : Nilai aktual pada periode ke t

b_t : Pemulus tren periode ke t

b_{t-1} : Pemulus tren periode ke $t-1$

γ : Nilai parameter pemulus tren ($0 < \gamma < 1$)

m : Periode ke depan yang akan diramalkan

F_{t+m}' : Nilai peramalan untuk $(t + m)$ periode ke depan

Proses inisialisasi untuk nilai taksiran S_t dan b_t dipilih dengan persamaan (5)

$$S_1 = b_1 \quad (5)$$

Penentuan nilai taksiran tren diperoleh dari persamaan (6)

$$b_t = X_2 - X_1 \quad (6)$$

Sumber : [20]

Dengan, kontanta alpha dan beta sebagai faktor pembobotan dan penentuan nilai parameter terbaik berkaitan dengan perhitungan *error* peramalan.

C. Perhitungan Tingkat Akurasi Peramalan

Tingkat akurasi digunakan untuk mengidentifikasi hasil peramalan dari faktor kesalahan *error* yang terjadi pada sistem perhitungan. Peramalan tidak dapat di akuratkan dengan nilai 100%, prinsip itu terjadi karena setiap peramalan akan memiliki standar *error* masing-masing pda setiap metode. Sehingga peramalan dikatakan baik apabila dapat meminimumkan nilai *error* dari batas toleransi. Adapun beberapa ukuran akurasi sebagai berikut [21] :

1. Root Mean Square Error (RMSE)

Akurasi pada *root mean square error* akan memberikan gambaran dari hasil peramalan berupa rendah maupun tinggi rentang nilai. Semakin kecil nilai akurasinya maka akan semakin baik hasil peramalannya. Persamaan *root mean square error* terlihat pada (7)

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (A_t - F_t)^2}{n}} \quad (7)$$

Sumber : [21]

2. Mean Absolute Percentage Error (MAPE)

Ukuran akurasi *mean absolute percentage error* digunakan untuk mengevaluasi kesalahan dalam bentuk persentase. Interpretasi rentang nilai *mean absolute percentage error* terlihat pada tabel 2.

Tabel 2. Rentang Nilai MAPE.

Rentang Nilai	Deskripsi
< 10%	Sangat akurat
10% - 20%	Akurat
20% - 50%	Cukup akurat
> 50%	Tidak akurat

Sumber : [22]

Persamaan menghitung nilai *mean absolute percentage error* terlihat pada (8)

$$\text{MAPE} = \frac{\sum_{t=1}^N |\text{PE}_t|}{N} \quad (8)$$

Sumber : [22]

III. HASIL DAN PEMBAHASAN

A. Pengumpulan Data

Data yang digunakan pada penelitian ini adalah data penjualan produk kerupuk pasir rentang waktu 4 tahun 6 bulan mulai dari bulan Januari 2019 hingga bulan Juni 2023.

Tabel 3. Jumlah Penjualan Kerupuk Pasir.

No.	Tanggal	Jumlah Penjualan
1.	02-Jan-19	23
2.	03-Jan-19	40
3.	04-Jan-19	59
4.	05-Jan-19	39
5.	06-Jan-19	48
....
....
1293.	25- Juni -23	69
1294.	27- Juni -23	76
1295.	28- Juni -23	84
1296.	29- Juni -23	81
1297.	30- Juni -23	23

Berdasarkan tabel 3 menunjukkan data yang digunakan penelitian peramalan penjualan. Dengan informasi data yaitu jumlah penjualan kerupuk pasir rentang waktu 4 tahun 6 bulan mulai dari bulan Januari 2019 hingga bulan Juni 2023.

B. Penentuan Sistem ANN

Teknik pengolahan data ini sering digunakan pada data mining untuk mengonversikan data agar dapat digunakan pada pengolahan selanjutnya karena data sudah memiliki informasi yang bersih. Pengecekan akan dilakukan pada tiga proses yang meliputi tes *missing value*, uji normalitas data, dan *partition* data.

1. Tes *missing value*

Tabel 4. Tes Missing Value.

Variabel	Data Valid	Data Missing	Percentage Valid
Tanggal Penjualan	1297	0	100%
Jumlah Penjualan (kg)	1297	0	100%

Berdasarkan tabel 4 menunjukkan varibel tanggal penjualan dan jumlah penjualan memiliki hasil *missing* sebesar 0 artinya sebanyak 1297 data tidak memiliki informasi yang hilang mengenai jumlah penjualan maupun tanggal penjualan. Dan dinyatakan *valid* dengan persentase sebesar 100% dan dapat dilakukan pada proses selanjutnya.

2. Uji normalitas data

Tabel 5. Uji Normalitas Data.

No.	Tanggal	Hasil Normalisasi Data	Keterangan
1.	02-Jan-19	0.197368421	Normal
2.	03-Jan-19	0.421052632	Normal
3.	04-Jan-19	0.671052632	Normal
4.	05-Jan-19	0.407894737	Normal
5.	06-Jan-19	0.526315789	Normal
....	Normal
....	Normal
1293.	25-Juni-23	0.802631579	Normal
1294.	27-Juni-23	0.894736842	Normal
1295.	28-Juni-23	1	Normal
1296.	29-Juni-23	0.960526316	Normal
1297.	30-Juni-23	0.197368421	Normal

Berdasarkan tabel 5 normalitas data menggunakan operator *normalize* pada *RapidMiner* untuk melatih data penjualan. Hasil normalisasi menghasilkan seluruh data dinyatakan normal dengan rentang nilai mendekati 0 sampai dengan 1. Selanjutnya dilakukan pembagian data yang terlihat pada tabel 6.

3. *Partition* data

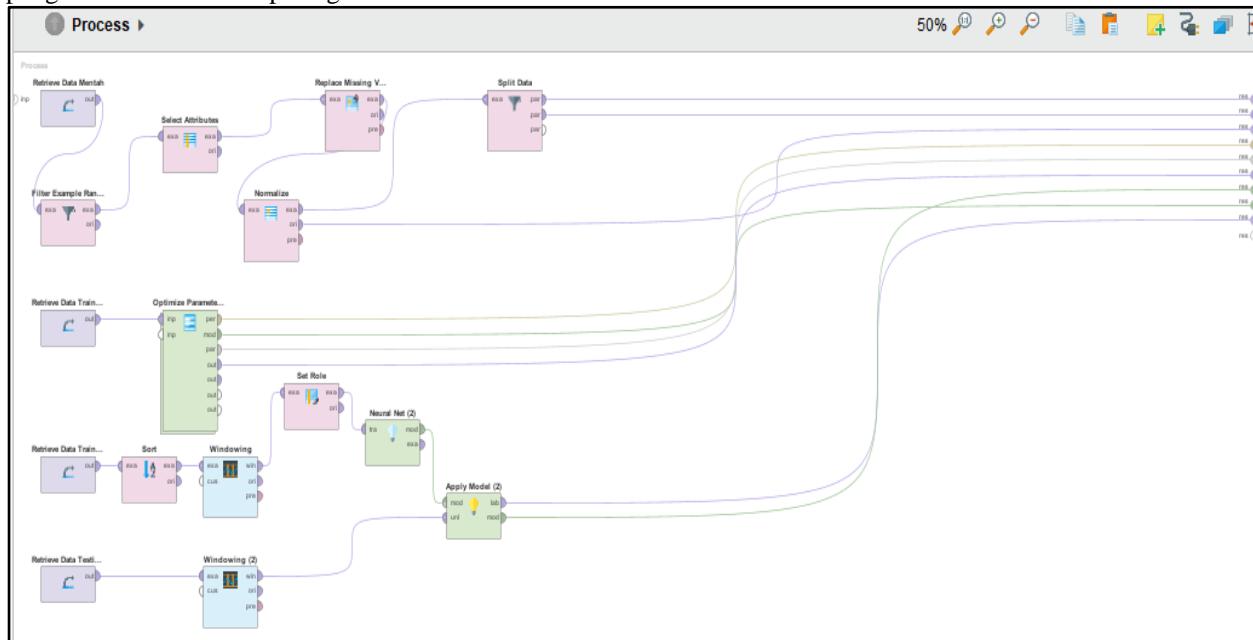
Tabel 6. Partition Data.

No.	Data Training (70%)		No.	Data Testing (30%)	
	Tanggal	Jumlah Penjualan		Tanggal	Jumlah Penjualan
1.	02-Jan-19	23	1.	12-Nov-21	13
2.	03-Jan-19	40	2.	13-Nov-21	33
3.	04-Jan-19	59	3.	14-Nov-21	37
4.	05-Jan-19	39	4.	15-Nov-21	32
5.	06-Jan-19	48	5.	16-Nov-21	38
...
...
904	7-Nov-21	24	385.	25-Juni-23	69
905	8-Nov-21	27	386.	27-Juni-23	76
906	9-Nov-21	28	387.	28-Juni-23	84
907	10-Nov-21	17	388.	29-Juni-23	81
908	11-Nov-21	30	389.	30-Juni-23	23

Berdasarkan tabel 6 *partition* data menggunakan operator *split* data dengan memasukkan nilai *ratio* pada *entry* sebesar 0,7 untuk data *training* dan 0,3 untuk data *testing*. Dari hasil *partition* data pada *RapidMiner* diperoleh data *training* sebanyak 912 data dan data *testing* sebanyak 385 data dengan metode pembagian *linear sampling*.

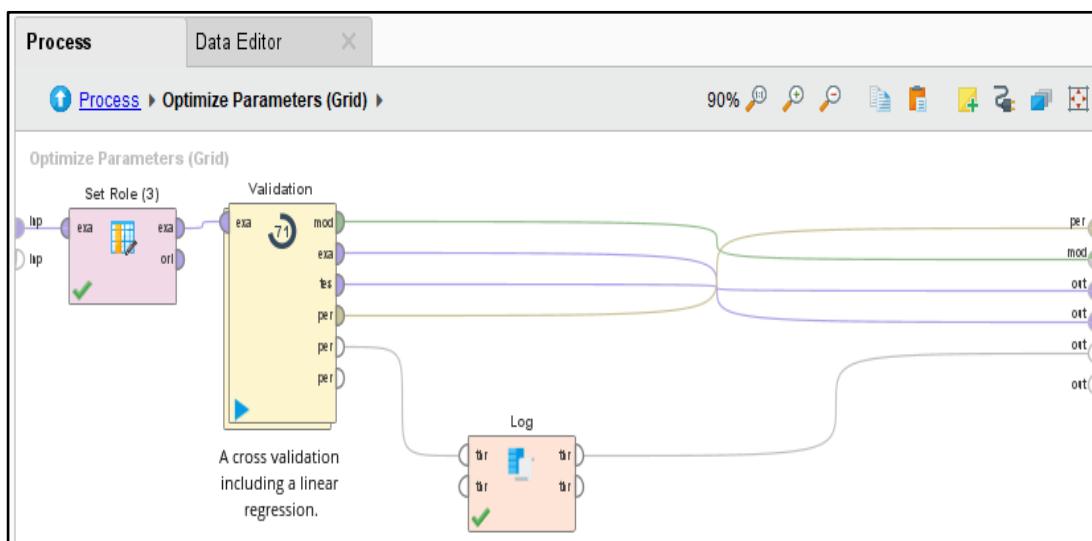
C. Aplikasi Artificial Neural network dengan Software RapidMiner

Pada pengaplikasian metode *artificial neural network* akan menggunakan *software RapidMiner* sebagai pengolahan data terlihat pada gambar 3 di bawah ini.



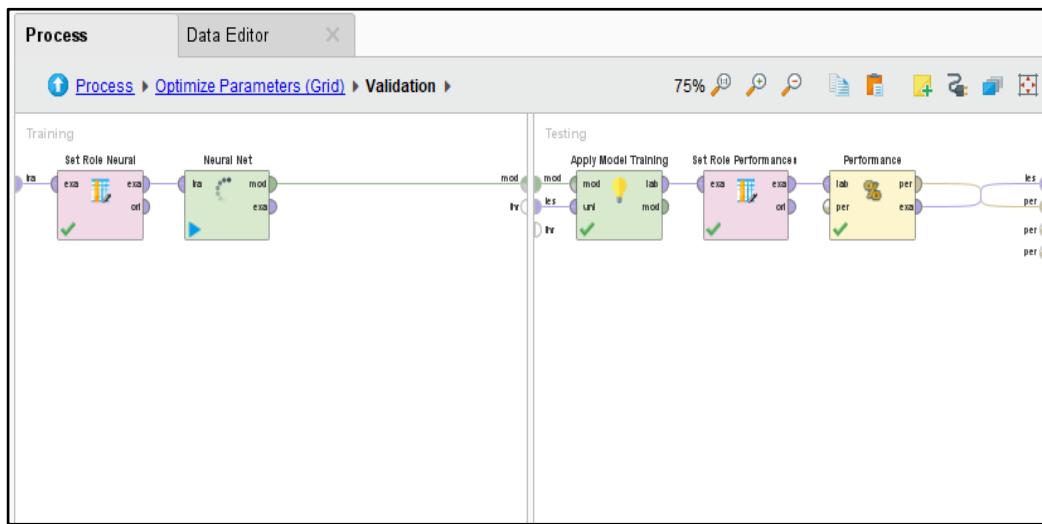
Gambar 3. Aplikasi Rancangan Artificial Neural Network Dengan Menggunakan Software RapidMiner.

Berdasarkan gambar 3 mengaplikasikan *artificial neural network* dengan *software rapidminer*. Tahapan dimulai dengan melakukan *preprocessing* data mentah. Dengan tahap awal mencari data yang tidak memiliki informasi dengan menggunakan operator *replace missing*. Setelah hasil data mendapatkan nilai 0 pada banyaknya data, maka dapat dilanjutkan ke proses selanjutnya yaitu normalisasi dengan menggunakan operator *normalize*. Hasil data normalisasi dikatakan sangat akurat apabila rentang nilai mendapatkan 0-1. Kemudian setelah data ternormalisasi dengan menyeluruh dilakukan pembagian data menggunakan operator *split data* dengan memasukkan *entry ratio* sebanyak 70% untuk data *training* dan 30% untuk data *testing*. Setelah *preprocessing* data berhasil dapat dilanjutkan pada proses selanjutnya seperti pada gambar 4.



Gambar 4. Subset Optimize parameter (grid).

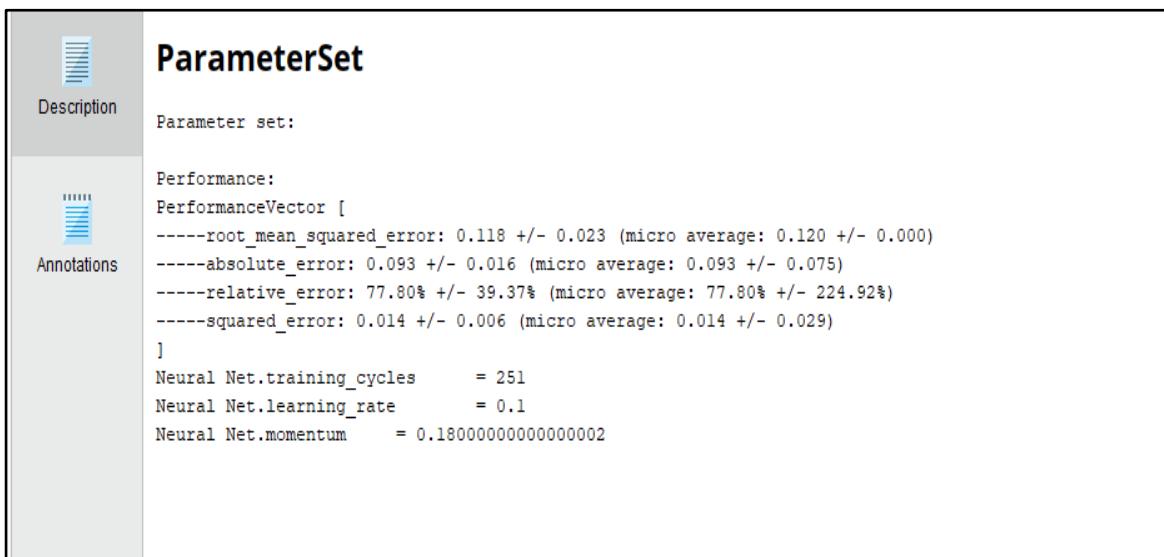
Pada gambar 4 data yang digunakan dalam tahap *training* dilakukan tahap *widnowing* terlebih dahulu untuk mengetahui jangka luasnya dalam peramalan yang dapat dilakukan. Kemudian melanjutkan pada tahap *optimize parameter (grid)*, dengan melakukan penentuan parameter yaitu parameter *learning rate*, momentum masing-masing memiliki nilai yang sama yaitu 0,1-0,9 dan *epoch* dengan jumlah maksimum sebanyak 500 iterasi.



Gambar 5. Subset Cross validation.

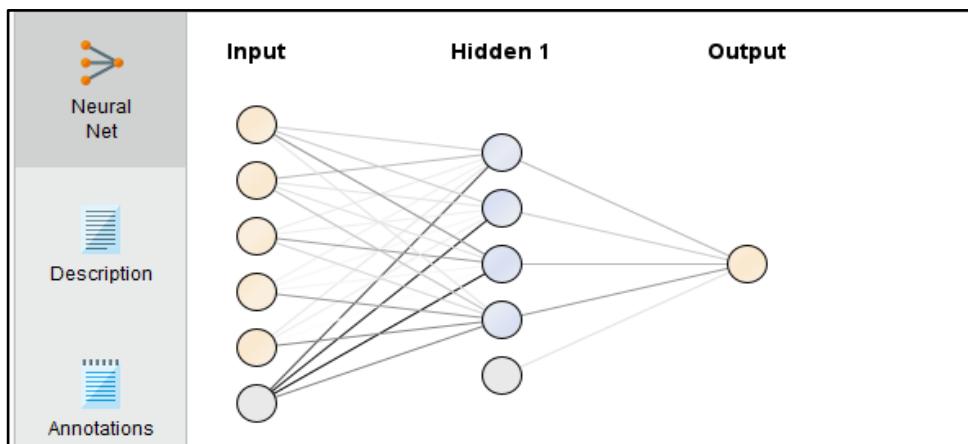
Pada gambar 5 menunjukkan operator ini terdapat sub proses yaitu operator *cross validation* yang terbagi dalam banyaknya k *subset* dengan jumlah yang sama untuk dihitung nilai rata-ratanya pada masing-masing k *subset*. Dari hasil k *subset* yang salah dalam percobaan akan digunakan sebagai acuan dalam peramalan dan pengujian data. Pada *cross validation* memiliki sub proses yaitu sub proses data *training* dan *testing*. Dengan kegunaan masing-masing pada sub proses ini memiliki perbedaan pada operator prosesnya. Proses *training* akan menggunakan operator *neural net* dan proses *testing* menggunakan operator *apply model* dan *performance*. Selanjutnya menuju pada proses *windowing* dengan menggunakan data *testing* yang telah diproses di *optimize parameter (grid)*. Kemudian dilakukan implementasi struktur model menggunakan operator *apply model* dan akan dihitung *root mean square error* sebagai perhitungan nilai *performance*.

Proses mengaplikasikan metode *artificial neural network* menggunakan *software RapidMiner* dapat ditunjukkan sebagai berikut. Setelah melalui proses *preprocessing* dan *windowing* hasil dari pelatihan data berupa *parameterset* dengan *performance* nilai akurasi peramalan, model rancangan arsitektur, dan hasil prediksi data *testing*.

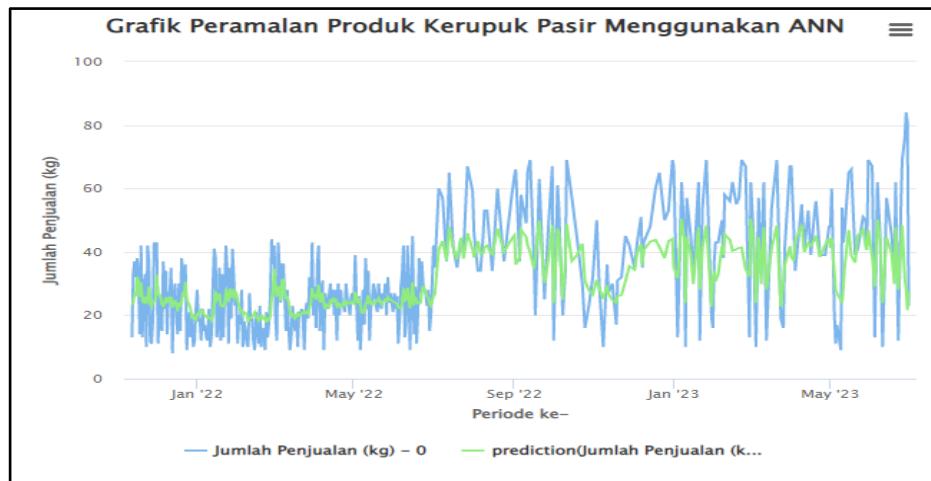


Gambar 6. Nilai Parameter Set RapidMiner

Pada gambar 6 menunjukkan hasil pada operator *optimize parameter (grid)* memiliki pola *training* dengan parameter yang telah ditentukan sebelumnya terdeteksi pada parameter *training cycles* memenuhi maksimum iterasi dengan nilai sebesar 251, pada parameter *learning rate* sebesar 0,1, dan pada parameter momentum sebesar 0,180. Dari gambar 6 dapat diidentifikasi pula hasil nilai *error* dengan ukuran akurasi yang telah di *input* sebelumnya pada proses *windowing*. Nilai *root mean square error* diperoleh sebesar 0,118 dengan *micro average* antara 0,120-0,000. Sehingga dapat dikategorikan hasil peramalan akurat karena mendekati angka 0.

**Gambar 7.** Rancangan Arsitektur *RapidMiner*

Pada gambar 7 menunjukkan operator *neural net* akan menghasilkan *output* berupa model rancangan arsitektur dari banyaknya data yang telah di *input*, selain itu juga memperoleh fungsi aktivasi yaitu *sigmoid*. Model yang telah terbentuk melalui proses *windowing* memperoleh hasil 6 *layer* pada lapisan *input*, 5 *layer* pada lapisan tersembunyi, dan 1 *layer* pada lapisan *output*. Dengan 4 *node* yang memiliki fungsi *sigmoid* masing-masing.

**Gambar 8.** Grafik Peramalan Penjualan Produk Menggunakan ANN.

Pada gambar 8 menunjukkan grafik peramalan penjualan produk menggunakan pengolahan data *Artificial Neural Network* (ANN) memiliki nilai signifikan yang mendekati pada data aktualnya. Dengan fungsi aktivasi *sigmoid*, model grafik tersebut memiliki bentuk yang linier dengan data aktual penjualan produk kerupuk pasir.

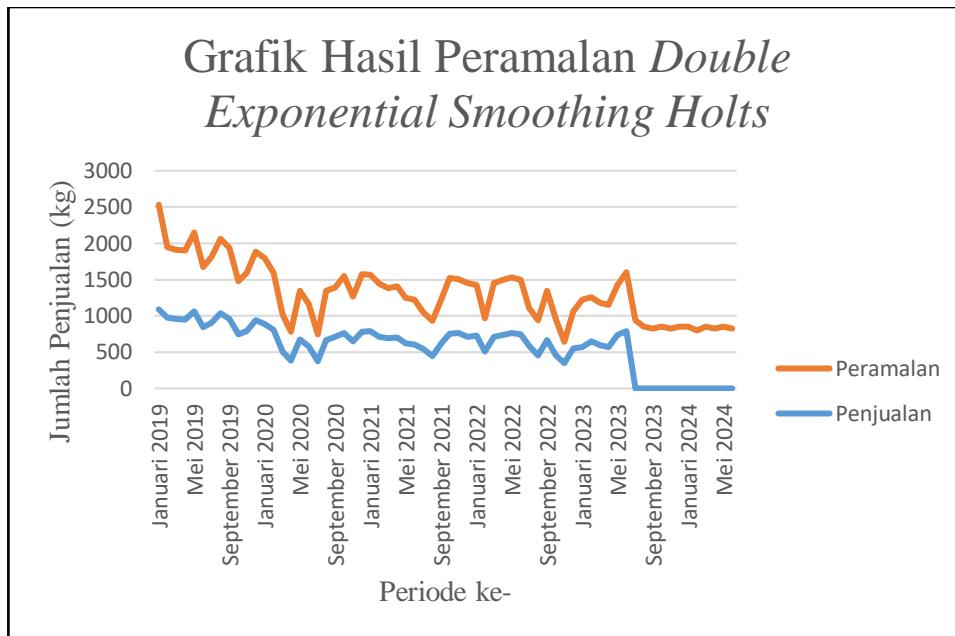
Tabel 7. Hasil Peramalan Kerupuk Pasir Metode ANN.

Date	Prediction (kg)
12-Nov-21	23
13-Nov-21	24
14-Nov-21	27
15-Nov-21	27
16-Nov-21	32
.....
.....
25-Jun-23	48
27-Jun-23	32
28-Jun-23	28
29-Jun-23	22
30-Jun-23	28

Berdasarkan tabel 7 menunjukkan hasil pengaplikasian rancangan *artificial neural network* diperoleh hasil peramalan yaitu prediksi total penjualan produk kerupuk pasir tahun 2023 sampai dengan 2024 yaitu pada bulan Juli sebesar 470, Agustus sebesar 415, September sebesar 532, Oktober sebesar 433, November sebesar 308, Desember sebesar 447, Januari sebesar 518, Februari sebesar 498, Maret sebesar 529, April sebesar 506, Mei sebesar 632, Juni sebesar 575.

D. Peramalan dengan Menggunakan Metode Double Exponential Smoothing Holts

Pada perhitungan peramalan yang akan dilakukan menggunakan metode *double exponential smoothing holts* memiliki ketentuan nilai alpha sebesar 0,3 dan beta sebesar 0,1 diperoleh hasil peramalan pada tabel 6 di bawah ini.



Gambar 9. Grafik Peramalan Metode Double Exponential Smoothing Holts.

Pada gambar 9 menunjukkan grafik peramalan penjualan produk menggunakan pengolahan data *double eksponential smoothing holts* memiliki nilai yang mendekati pada data penjualan aktual. Dengan, model grafik tersebut memiliki bentuk yang linier dengan data aktual penjualan produk kerupuk pasir.

Tabel 8. Hasil Peramalan Dengan Menggunakan Metode Double Exponential Smoothing Holts.

No.	Tanggal, Bulan, Tahun	Jumlah Penjualan (kg)
1.	12-Nov-21	26
2.	13-Nov-21	25
3.	14-Nov-21	25
4.	15-Nov-21	21
5.	16-Nov-21	23
...
...
8.	25-Jun-23	27
9.	27-Jun-23	27
10.	28-Jun-23	27
11.	29-Jun-23	27
12.	30-Jun-23	27

Berdasarkan tabel 8 menunjukkan hasil peramalan menggunakan metode *double exponential smoothing holts* secara berturut-turut tahun 2023 sampai dengan 2024 yaitu pada bulan Juli sebesar 941, Agustus sebesar 851, September sebesar 823, Oktober sebesar 851, November sebesar 824, Desember sebesar 851, Januari sebesar 851, Februari sebesar 1127, Maret sebesar 851, April sebesar 824, Mei sebesar 851, Juni sebesar 824.dengan nilai RMSE sebesar 11,639.

Dari hasil peramalan pada kedua metode tersebut dapat di analisa perbandingan *root mean square error* pada metode *artificial neural network* memiliki nilai *error* sebesar 0,118 dari pada metode *double exponential smoothing holts* diperoleh nilai *error* sebesar 11,639. Sehingga dapat diidentifikasi bahwa metode *artificial neural network* memiliki perhitungan yang lebih akurat dibandingkan metode *double exponential smoothing holts*. Hasil penelitian ini juga sesuai dengan diteliti oleh Tantyo dalam jurnal penelitian bahwa metode *artificial neural network* memiliki tingkat akurasi lebih baik dibandingkan dengan metode *holts*.

IV. SIMPULAN

Simpulan dari penelitian yang telah dilakukan yaitu metode *artificial neural network* menghasilkan nilai *root mean square error* sebesar 0,118 dan metode *double exponential smoothing holts* menghasilkan nilai sebesar 11,639. Dengan hasil peramalan yang diperoleh berturut-turut selama 12 periode pada *artificial neural network* yaitu bulan bulan Juli sebesar 470, Agustus sebesar 415, September sebesar 532, Oktober sebesar 433, November sebesar 308, Desember sebesar 447, Januari sebesar 518, Februari sebesar 498, Maret sebesar 529, April sebesar 506, Mei sebesar 632, Juni sebesar 575. Dan model *artificial neural network* memiliki 6 *node input* yang meliputi 5 *node hidden layer* dan 1 *node output*. Dengan nilai *root mean square error* terkecil terdapat pada metode *artificial neural network* artinya cukup akurat. Yang artinya penjualan pada periode juli 2023 sampai dengan Mei 2024 mengalami penurunan. Maka untuk mengantisipasi penjualan tersebut perlu dilakukan pengendalian persediaan bahan baku untuk perbaikan terhadap perencanaan pemesanan bahan baku, guna menghindari permasalahan kekurangan dan kelebihan bahan baku yang pernah terjadi di UD. XYZ. Selain itu, model rancangan *artificial neural network* akan dipilih sebagai metode dalam mengestimasi penjualan produk kerupuk pasir pada periode selanjutnya.

UCAPAN TERIMA KASIH

Terimakasih diucapkan kepada karyawan bagian produksi UD. XYZ yang telah bersedia memberikan izin dalam kepercayaan memberikan amanah atas data yang dilakukan untuk penelitian di lokasi tersebut. Bapak/ibu dosen yang telah memberi bimbingan sehingga penelitian ini dapat terselesaikan dengan baik serta semua pihak yang terlibat dalam penyelesaian penelitian ini.

REFERENSI

- [1] A. Lusiana, P. Yuliarty, "Penerapan Metode Peramalan (Forecasting) Pada Permintaan Atap di PT X", Jurnal Teknik Industri, vol. 10, no. 5, pp. 11-20, 2020.
- [2] B. W. N. Tantyo, D. Swanjaya, "Perbandingan Antara Metode Holt Winter Dan Backpropagation Pada Model Peramalan Penjualan" Jurnal Seminar Nasional Inovasi Teknologi, vol. 3, no. 1, pp. 174-181, 2021.
- [3] A. Dzulfikar, Iswanto, N. Ramsari, S. Sutjiningtyas, Hernawati, "Implementasi Peramalan Penjualan Produk di PT. Prima Per Tradea Utama Menggunakan Metode Artificial Neural Network", Jurnal Teknologi Informasi dan Komunikasi, vol. 11, no. 2, pp.10-11, 2021.
- [4] I. Solikin, S. Hardini, "Aplikasi Forecasting Stok Barang Menggunakan Metode Weighted Moving Average (WMA) Pada Metrojaya Komputer", Jurnal Pengembangan, vol. 4, no. 2, pp. 100-105, 2019, doi: 10.3059/jpt.v4i2.1373.
- [5] J. R. Saragih, M. B. S. Saragih, A. Wanto, "Analisis Algoritma Backpropagation Dalam Prediksi Nilai Ekspor (Juta USD)", Jurnal Pendidikan Teknologi dan Kejuruan, vol. 15, no. 2, pp. 254-264, 2018, doi: <https://ejournal.undiksha.ac.id/index.php/JPTK/issue/view/851>.
- [6] I. Yulian, D. S. Anggraeni, Q. Aini. "Penerapan Metode Trend Moment Dalam Forecasting Penjualan Produk CV. Rabbani Asyisa", Jurnal Teknologi dan Sistem Informasi, vol. 6, no. 2, pp. 193-200, 2020, doi: <https://doi.org/10.33330/jurteksi.v6i2.443>.
- [7] E. E. Pratama, H. Sastypratiwi, Yulianti, "Analisis Kecenderungan Informasi Terkait Covid-19 Berdasarkan Big Data Sosial Media Dengan Menggunakan Metode Data Mining", Jurnal Informasi Polinema, vol. 7, no. 2, pp. 1-6, 2021.
- [8] J. Han, M. Kamber, J. Pei. "Data Mining Concepts And Techniques" Edisi ke-3, USA: Morgan Kaufmann, 2006.
- [9] Z. Nabilah, A. R. Isnain, Z. Abidin, "Analisis Data Mining Untuk Clustering Kasus Covid-19 Di Provinsi Lampung Dengan Algoritma K-Means", Jurnal Teknologi dan Sistem Informasi, vol. 2, no. 2, pp. 100-108, 2021.
- [10] B. Santosa, A. Umam, "Data Mining dan Big Data Analytics", Edisi ke-2, Yogyakarta: Penebar Media Pustaka, 2018.
- [11] H. D. Wijaya, S. Dwiasnati, "Implementasi Data Mining Dengan Algoritma Naïve Bayes Pada Penjualan Obat", Jurnal Informatika, vol. 7, no. 1, pp. 1-7, 2020.

- [12] M. N. Zain, "Algoritma Artificial Neural Network Dalam Klasifikasi Chest X-Rays Pasien Covid-19", Jurnal Riset Statistika, vol. 2, no. 2, pp. 137-144, 2022. Doi: <https://doi.org/10.29313/jrs.v2i2.1426>.
- [13] M. F. Mahfuzh, R. V. Yuliantari, "Analisis Penerapan Artificial Neural Network Algoritma Propagasi Balik Untuk Meramalkan Harga Saham Pada Bursa Efek Indonesia", vol. 6, no. 1, pp. 1-3, 2022.
- [14] N. F. Hasan, Kusrini, H. A. Fatta, "Peramalan Jumlah Penjualan Menggunakan Jaringan Syaraf Tiruan Backpropagation Pada Perusahaan Air Minum Dalam Kemasan", Jurnal Teknik Informatika dan Sistem Informasi, vol. 5, no. 2, pp. 179-188, 2019.
- [15] A. Ambarwati, Q. J. Adrian, Y. Herdiyeni, "Analisis Pengaruh Data Scaling Terhadap Performa Algoritme Machine Learning Untuk Identifikasi Tanaman", Jurnal Rekayasa Sistem dan Teknologi Informasi, vol. 4, no. 1, pp. 117-122, 2019, <http://jurnal.iaii.or.id>.
- [16] M. Y. Habibi, E. Riksakomara, "Peramalan Harga Garam Konsumsi Menggunakan Artificial Neural Network Feedforward Backpropagation (Studi Kasus: PT. Garam, Rembang, Jawa Tengah)", Jurnal Teknik, vol. 6, no. 2, pp. 306-310, 2018
- [17] V. N. Oktavianty, T. Sukmono, "Optimalisasi Penentuan Biaya Minimum Pada Pengendalian Persediaan Bahan Baku Dengan Menggunakan Metode Dynamic Programming (Studi Kasus di PT. XYZ)", Jurnal Spektrum Industri, vol. 18, no. 1, pp. 18-22, 2020, doi: <http://dx.doi.org/10.12928/si.v18i1.10972>
- [18] C.V. Hudiyanti, F. A. Bachtiar, B. D. Setiawan, "Perbandingan Double Moving Average dan Double Exponential Smoothing Untuk Peramalan Jumlah Kedatangan Wisata Mancanegara di Bandara Ngurah Rai", Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, vol. 3, no. 3, pp. 2667-2672, 2019.
- [19] M. A. Putri, T. Sukomo, "Analisa Peramalan Penjualan Kerupuk Udang Dengan Menggunakan Metode Artificial Neural Network (ANN)", pp. 1-9, 2022.
- [20] Humairo, D. P. Habsari, I. Purnamasari, D. Desi Yuniar, "Peramalan Menggunakan Metode Double Exponential Smoothing Dan Verifikasi Hasil Peramalan Menggunakan Grafik Pengendalian Tracking Signal", Jurnal Ilmu Matematika dan Terapan, vol. 14, no.1, pp. 013-022, 2020, doi: <https://doi.org/10.30598/barekengvol14iss1pp013-022>.
- [21] K. R. P. Irawan, T. Sukmono, "Planning Total Veener Production PT XYZ", Jurnal Procedia Of Engineering And Life Science, vol. 1, no.2, 2021.
- [22] D. Kusbiamto, Y. Ariyanto, M. R. T. Billah, "Implementasi Metode Triple Exponential Smoothing Pada Sistem Peramalan Permintaan Produk Furniture", Jurnal Informatika Aplikatif Polinema, 2020.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.