

Perbandingan *Holt-Winters Exponential Smoothing* dengan *Artificial Neural Networks* dalam Peramalan Produksi Cabai Besar di Kabupaten Garut Provinsi Jawa Barat

Ihram Adi Pratama*, Anneke Iswani Achmad

Prodi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Islam Bandung, Indonesia.

*ihrama13@gmail.com, annekeiswani11@gmail.com

Abstract. This study discusses the comparison of *Holt-Winters Exponential Smoothing* method with *Artificial Neural Networks* in forecasting large chili production, Garut Regency, West Java Province. The *Holt-Winters Exponential Smoothing* method is a forecasting method on time series data with trend and seasonal data patterns based on three equations, one for stationary, one for trend and one for seasonal. There are two methods in *Holt-Winters Exponential Smoothing*, namely multiplicative and additive. *Artificial Neural Networks* is a method inspired by human central neural networks. One method that can be used for forecasting in ANN is *Neural Network Autoregression* or NNAR. NNAR can be used to forecast forecasting through pattern recognition from inputs by utilizing lag values as inputs and then refined through the learning process using *Backpropagation* Algorithms. This method comparison uses RMSE (*Root Mean Squared Error*) to see the accuracy of forecasting accuracy. The data used is secondary data from the large chili production of Garut Regency in 2016 – 2022. Analysis of both methods resulted in the smallest RMSE value or forecasting accuracy on NNAR with RMSE Testing of 39,490.91. So to forecast m future period, you can use the *Artificial Neural Networks* method with *Neural Network Autoregression* because it has a smaller RMSE value.

Keywords: *Holt Winter Exponential Smoothing, Artificial Neural Network, Big Chili Production.*

Abstrak. Penelitian ini membahas mengenai perbandingan metode *Holt-Winters Exponential Smoothing* dengan *Artificial Neural Networks* dalam peramalan produksi cabai besar Kabupaten Garut Provinsi Jawa Barat. Metode *Holt-Winters Exponential Smoothing* merupakan metode peramalan pada data deret waktu dengan pola data trend dan musiman yang didasarkan pada tiga persamaan yaitu satu untuk stasioner, satu untuk trend dan satu untuk musiman. Terdapat dua metode dalam *Holt-Winters Exponential Smoothing* yaitu multiplikatif dan aditif. *Artificial Neural Networks* merupakan metode yang terinspirasi dari jaringan saraf pusat manusia. Salah satu metode yang dapat digunakan untuk peramalan dalam ANN adalah *Neural Network Autoregression* atau NNAR. NNAR dapat digunakan untuk memperkirakan peramalan melalui pengenalan pola dari input dengan memanfaatkan nilai lag sebagai input dan kemudian disempurnakan melalui proses pembelajaran menggunakan Algoritma *Backpropagation*. Perbandingan metode ini menggunakan RMSE (*Root Mean Squared Error*) untuk melihat akurasi ketepatan peramalan. Data yang digunakan adalah data sekunder dari produksi cabai besar Kabupaten Garut tahun 2016 – 2022. Analisis kedua metode tersebut menghasilkan nilai RMSE atau ketepatan peramalan terkecil pada NNAR dengan RMSE Pengujian sebesar 39.490,91. Sehingga untuk meramalkan m periode kedepan dapat menggunakan metode *Artificial Neural Networks* dengan *Neural Network Autoregression* karena memiliki nilai RMSE lebih kecil.

Kata Kunci: *Holt Winter Exponential Smoothing, Artificial neural Network, Produksi Cabai Besar.*

A. Pendahuluan

Peramalan merupakan sebuah teknik untuk memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data saat ini (Aswi dan Sukarna, 2006). Metode Pemulusan eksponensial tripel dari Winters lebih dikenal sebagai metode *Holt-Winters* merupakan metode peramalan yang didasarkan pada tiga persamaan yaitu satu untuk stasioner, satu untuk trend dan satu untuk musiman. Metode *Holt-Winters Exponential smoothing* dapat mengatasi pola trend dan musiman yang teratur (Makridakis dkk, 1999). Namun, dalam metode *Holt-Winters Exponential smoothing* diperlukan menentukan indeks musiman yang tepat dan terdapat parameter pembobot untuk pola tren dan musiman yang sensitif sehingga perlu dengan cermat menentukan parameter tersebut.

Untuk mengatasi apabila musiman tidak teratur maka dapat menggunakan Metode *Artificial Neural Network* atau ANN. ANN merupakan metode yang terinspirasi dari jaringan saraf pusat manusia. ANN memiliki berbagai jenis metode peramalan. Salah satu metode yang dapat digunakan untuk peramalan dalam ANN adalah *Neural Network Autoregression* atau NNAR. NNAR dapat digunakan untuk memperkirakan peramalan berdasarkan volume yang besar melalui pengenalan pola dari *input* dan kemudian disempurnakan melalui proses pembelajaran sehingga mampu memodelkan hubungan non-linier dengan masalah yang kompleks tanpa sebelumnya ada asumsi hubungan yang mendasarinya (Setyawan, 2021). Dalam metode NNAR memerlukan volume data yang cukup sehingga dapat memodelkan dengan hasil yang lebih representatif.

Selain itu kedua metode ini merupakan metode analisis *time series* sehingga dapat memperkirakan ketidakpastian produksi yang dihasilkan. Hal ini sesuai dengan sifat perubahan produksi hasil tanaman yang biasanya mengalami kenaikan atau penurunan dari waktu ke waktu, juga dipengaruhi oleh musim seperti cuaca dan yang lainnya. Kabupaten Garut menjadi daerah yang paling berpotensi dalam meningkatkan produksi cabai besar karena memiliki luas panen yang besar dan kondisi yang hangat untuk pertumbuhan cabai, berdasarkan data produksi cabai besar Badan Pusat Statistik Provinsi Jawa Barat tahun 2016 – 2022 di Kabupaten Garut selalu meningkat dan memiliki hasil produksi terbanyak setiap tahunnya. Akan tetapi walaupun menjadi produksi terbanyak di Provinsi Jawa Barat terdapat ketidakstabilan produksi dalam setiap bulannya. Ketidakstabilan ini dapat menyebabkan permasalahan seperti tidak tercukupinya produksi dalam negeri yang membuat pemerintah harus melakukan Impor dari luar negeri dikarenakan konsumsi cabai besar meningkat setiap tahunnya (Agnesya Risnandar & Anneke Iswani Achmad, 2023).

Berdasarkan kondisi pada Kabupaten Garut, menjaga kestabilan dan meningkatkan potensi produksi cabai besar harus tetap di upayakan oleh petani yaitu dengan melakukan peramalan untuk memperkirakan hasil produksi di masa yang akan datang. Dalam melakukan peramalan diperlukan nilai yang akurat dan tepat. Untuk itu dengan data produksi Cabai Besar Badan Pusat Statistik Jawa Barat Kabupaten Garut tahun 2016-2022 dan metode yang sesuai diharapkan mendapatkan nilai peramalan yang tepat sebagai pertimbangan untuk meningkatkan potensi produksi cabai besar dan menjaga kestabilan produksi cabai besar di Kabupaten Garut dengan melihat perbandingan menggunakan metode *Holt-Winters Exponential Smoothing* dan *Artificial Neural Network* untuk dilihat nilai akurasi yang terbaik. Selanjutnya tujuan dari penelitian ini adalah:

1. Untuk mengetahui perbandingan metode *Holt-Winters Exponential Smoothing* dan *Artificial Neural Networks* menggunakan nilai RMSE (*Root Mean Squared Error*) terkecil pada hasil peramalan produksi cabai besar Kabupaten Garut Provinsi Jawa Barat pada bulan Januari 2016 – Desember 2022
2. Untuk mengetahui hasil peramalan produksi cabai besar Kabupaten Garut Provinsi Jawa Barat pada bulan Januari 2023 – Desember 2023 dengan metode terbaik.

B. Metodologi Penelitian

Penelitian ini menggunakan data sekunder yang bersumber dari *website* Badan Pusat Statistik Provinsi Jawa Barat dengan data yang digunakan yaitu data produksi cabai besar Kabupaten Garut mulai dari bulan Januari 2016 hingga Desember 2022. Data ini berjumlah 84 pengamatan.

Metode Analisis Data

Data Deret Waktu

Data deret waktu merupakan data yang telah dikumpulkan, dicatat atau diidentifikasi selama berjalannya waktu secara berurutan. Data deret waktu dianalisis agar dapat menemukan pola variasi dimasa lalu yang akan dipergunakan untuk memperkirakan nilai masa depan dan dapat membantu manajemen operasi serta dalam membuat perencanaan.

Pemulusan Eksponensial Tiga Parameter dari Holt-Winter

Menurut Rosadi (2011), apabila pada data terdapat komponen *trend* dan musiman, dapat menggunakan metode pemulusan *Holt-Winters*, yang memerlukan tiga parameter pemulusan, yaitu α (untuk “level” dari proses), β (untuk pemulusan *trend*) dan γ (untuk komponen musiman). Menurut (Makridakis dkk, 1999) nilai-nilai pada α, β , dan γ tersebut yang akan meminimumkan nilai *error*. Terdapat dua metode *Holt-Winters*, yaitu metode *Holt-Winters* aditif (penjumlahan) dan metode *Holt-Winters* multiplikatif (perkalian).

Holt-Winters Multiplikatif (Perkalian)

Model *Holt-Winters* digunakan jika pola data asli menunjukkan fluktuasi data musiman yang beragam (Markridakis, dkk 1999). Adapun Persamaan peramalan pada periode m kedepan dengan metode ini dirincikan dalam persamaan berikut:

$$F_{t+m} = (S_t + b_t \times m) \times I_{t-L+m} \quad (1)$$

Holt-Winters Aditif (Penjumlahan)

Model *Holt-Winters* digunakan jika pola data asli menunjukkan fluktuasi data musiman yang teratur atau konsisten (Markridakis, dkk 1999). Adapun Persamaan peramalan pada periode m ke depan dengan metode ini dirincikan dalam persamaan berikut:

$$F_{t+m} = S_t + b_t \times m + I_{t-L+m} \quad (2)$$

Dengan keterangan untuk multiplikatif dan aditif:

I_{t-L+m} : pemulusan musiman $t = 1, 2, \dots, t - L$ periode m kedepan

F_{t+m} : nilai peramalan m periode depan

S_t : pemulusan eksponensial atau level ke- t

b_t : pemulusan trend ke- t

m : Nilai periode ke depan $m = 1, 2, \dots, m$


Partial Autocorrelation Function (PACF)

Autokorelasi parsial digunakan untuk mengukur tingkat keeratan antara X_t dan X_{t+k} , apabila pengaruh dari lag 1, 2, dan seterusnya hingga $t+k-1$ dianggap menjadi terpisah, fungsi auto korelasi parsial dapat dinotasikan dengan $(corr X_t, X_{t+k} | X_{t+1}, \dots, X_{t+k-1})$ (Makridaskis dkk, 1999).

Rumus umum PACF pada lag ke- k yaitu sebagai berikut :

$$\phi_k = (P_k)^{-1} \rho_k \quad (3)$$

Melalu plot, PACF dapat ditentukan sebagai berikut



Gambar 1. Pola PACF

Melalui gambar 1 pada pola PACF dapat terlihat yang melebihi garis signifikansi merupakan lag dari data.

Artificial Neural Networks (ANN)

Artificial Neural Network atau Jaringan Syaraf Tiruan merupakan model matematis yang mencoba untuk mensimulasikan struktur dan fungsi jaringan saraf biologis. Ada berbagai macam jaringan syaraf tiruan yang dapat digunakan untuk memodelkan jaringan syaraf nyata seperti pengenalan pola, peramalan, dan kompresi data. Untuk peramalan jaringan syaraf tiruan dapat menggunakan metode *Generalised Regression Neural Network*, *Neural Network Autoregressive*, *Multi-layer perceptron*, *Extreme Learning Machine* (Twumasi, 2022).

Neural Network Autoregression (NNAR)

Salah satu metode yang dapat digunakan untuk peramalan dalam ANN adalah *Neural Network Autoregression* atau NNAR. NNAR merupakan jaringan syaraf tiruan yang relatif baru dengan memanfaatkan nilai lag (nilai deret waktu yang tertinggal) sebagai variabel *input* menggunakan *Partial Autocorrelation Function* untuk meramalkan nilai masa depan menggunakan Algoritma *Backpropagation*. Metode ini diperkenalkan oleh Hyndman dan Athanasopoulos pada tahun 2018 dengan memanfaatkan *Software open-source R*.

Menurut Hyndman dan Athanasopoulos (2018) *input* dalam metode *Neural Network Autoregression* dilambangkan dengan p dan lapisan tersembunyi atau *hidden layer* dilambangkan sebagai k sehingga dapat dilambangkan sebagai model NNAR (p, k). *Input* dapat diperoleh berdasarkan lag dari data. Untuk lapisan tersembunyi dapat ditentukan secara tentatif dengan memvariasikan nilai k kemudian dilakukan *trial and error*. Nilai k dapat divariasikan mengikuti aturan *rule of thumb* (Setyawan, 2021)

$$k = \frac{N_s}{\gamma(N_i + N_o)} \quad (4)$$

Keterangan :

γ : Suatu konstanta, bernilai 2 sampai dengan 5


N_s : Banyaknya data sampel

N_i : Banyaknya node pada *input layer*

N_o : Banyaknya node pada *output layer*

Algoritma Backpropagation

Algoritma *Backpropagation* merupakan algoritma untuk mendapatkan nilai bobot dalam pengenalan pola. Algoritma *Backpropagation* bertujuan untuk meminimumkan tingkat kesalahan atau *error* dengan menyesuaikan bobot dan bias suatu jaringan. Menurut Siang J.J (2005) pada pelatihan *Backpropagation* meliputi tiga fase yaitu fase 1 propagasi maju, fase 2 propagasi mundur dan fase 3 perubahan bobot. Ketiga fase dilakukan secara berulang hingga proses iterasi berhenti berdasarkan ketentuan *error* yang di dapatkan sudah sesuai dengan batas toleransi *error* yang di inginkan atau kondisi stop sudah terpenuhi. Dalam prosesnya terdapat fungsi aktivasi untuk menentukan output. Arsitektur dapat dijelaskan sebagai berikut:



Gambar 2. Ilustarsi Arsitektur Jaringan NNAR (2,1)

Gambar 2 menunjukkan ilustrasi dari topologi NNAR dengan menggunakan 2 unit *input* dan sebuah *hidden layer* menghasilkan sebuah *output* dalam setiap *input layer* dan *hidden layer* ditambah sebuah bias. Pelatihan *Neural Network Autoregression* dengan algoritma *Backpropagation* menggunakan fungsi *non linier* yang dapat dijelaskan sebagai berikut (Fausett, 1994):

$$x_{in_j} = v_{01} + \sum_{i=1}^n z_i v_{i1} \quad (5)$$

Dengan menggunakan fungsi aktivasi log sigmoid sebagai berikut:

$$x_j = f(x_{in}) = \frac{1}{1 + e^{-x_{in_j}}} \quad (6)$$

Pengukuran ketepatan peramalan

Semakin kecil nilai RMSE yang dihasilkan, maka metode yang digunakan semakin baik (Makridakis dan Wheelwright, 1999). RMSE dituliskan dengan persamaan sebagai berikut :

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_i - F_t)^2}{y_i}} \quad (7)$$

dengan keterangan:

n : jumlah data

y_i : data ke- i

F_t : nilai peramalan pada periode ke- t

Langkah dan Metode *Holt-Winters Exponential Smoothing*

1. Eksplorasi Data
2. Melakukan partisi data menjadi pelatihan dan pengujian menggunakan komposisi 85% untuk pelatihan dan 15% untuk pengujian
3. Menentukan nilai awal pemulusan metode multiplikatif dan aditif
4. Menentukan nilai parameter terbaik untuk multiplikatif dan aditif
5. Menghitung nilai pemulusan metode multiplikatif dan aditif
6. Membentuk model peramalan metode multiplikatif dan aditif.
7. Menghitung nilai peramalan data pengujian 15% metode multiplikatif dan aditif.
8. Pengukuran ketepatan peramalan dengan menghitung RMSE data pengujian.
9. Perbandingan ketepatan peramalan.
10. Peramalan untuk 12 periode kedepan pada bulan Januari 2023- Desember 2023 dengan metode terbaik.

Langkah dan Metode *Artificial Neural Network*

1. Melakukan partisi data menjadi pelatihan dan pengujian menggunakan komposisi 85% untuk proses pelatihan dan 15% untuk pengujian.
2. Menentukan nilai *input* berdasarkan keterlambatan yang bergantung pada jumlah dalam lag dan lapisan tersembunyi secara tentatif
3. Melakukan proses pelatihan jaringan dengan *software R Studio*.
4. Menghitung nilai peramalan data pengujian 15% dengan *software R Studio*.
5. Pengukuran ketepatan peramalan dengan menghitung RMSE data pengujian.
6. Perbandingan ketepatan peramalan.
7. Peramalan untuk 12 periode kedepan pada bulan Januari 2023 – Desember 2023 dengan metode terbaik.


C. Hasil Penelitian dan Pembahasan

Pembagian Data

Machine learning menggunakan sampel untuk menyimpulkan kondisi pada suatu populasi yaitu melakukan pembagian data pelatihan dan pengujian. Data pelatihan digunakan untuk membangun model, sedangkan data pengujian digunakan untuk menguji model setelah proses

latihan selesai. Secara umum pembagian dapat menjadi (50%; 50%), (70%; 30%), atau (80%; 20%) (Setyawan, 2021). Namun data pengujian dapat disesuaikan berdasarkan data lapangan, sehingga dapat digunakan 10% sampai 30% data terakhir (Aisyah dkk, 2021). Dalam analisis kedua metode ini dilakukan pembagian data menjadi pelatihan dan pengujian menggunakan komposisi 85% untuk pelatihan dan 15% untuk pengujian. Data pelatihan dimulai dari bulan Januari 2016 hingga bulan Desember 2021.

Analisis Metode *Holt Winters Exponential Smoothing* Eksplorasi Data



Gambar 3. Pola Data Produksi Cabai besar 2016-2022

Data produksi cabai besar merupakan data runtun waktu sehingga dapat dibuat *time series plot*. Berdasarkan pada gambar 4.1, produksi cabai besar di Kabupaten Garut menunjukkan variasi trend dan musiman.

Menentukan Nilai Awal Pemulusan Multiplikatif dan Aditif

1. Nilai Awal Pemulusan Level

$$S_L = \left(\frac{X_1 + X_2 + \dots + X_{12}}{L} \right)$$

$$S_L = 67.285,67$$

2. Nilai Awal Pemulusan Trend

$$b_L = \frac{1}{12} \left(\frac{X_{12+1} - X_1}{12} + \frac{X_{12+2} - X_2}{12} + \dots + \frac{X_{12+12} - X_{12}}{12} \right)$$

$$b_L = 1.502,94$$

3. Nilai Awal Pemulusan Musiman

Tabel 1. Nilai Awal Pemulusan Musiman Multiplikatif dan Aditif

I_p	Multiplikatif $\left(\frac{X_p}{S_L} \right)$	Multiplikatif $(X_p - S_L)$
I_1	0,8847	-7.755,67
I_2	1,7713	51.899,33
I_3	1,4495	30.245,33
I_4	1,5398	36.321,33
I_5	0,7271	-18.361,67
I_6	1,3429	23.071,33
I_7	1,5174	34.810,33
I_8	0,5173	-32.480,67
I_9	0,5567	-29.828,67
I_{10}	0,4242	-38.740,67
I_{11}	0,5940	-27.316,67
I_{12}	0,6751	-21.863,67

Mencari Nilai Parameter Pemulusan Multiplikatif dan Aditif

Setelah mendapatkan nilai awal pemulusan, untuk melakukan perhitungan nilai S_t, b_t, I_t pada model *Holt-Winters* Multiplikatif diperlukan nilai parameter yang dapat diperoleh melalui *software excel* dengan fungsi *solver* bernilai antara 0 sampai 1. Sehingga diperoleh sebagai berikut.

Tabel 2. Nilai Parameter Pemulusan Multiplikatif dan Aditif

Metode	Parameter		
	α	β	γ
Aditif	0,1519	0,027	0,5418
Multiplikatif	0,3193	0	0,6046

Menghitung Nilai Pemulusan Multiplikatif dan Aditif

Perhitungan nilai pemulusan level, trend dan musiman pada saat $t = 13$ sampai dengan $t = 72$ adalah sebagai berikut :

Nilai Pemulusan Multiplikatif

1. Nilai Pemulusan Level

$$S_t = \alpha \frac{X_{13}}{I_{13-12}} + (1 - \alpha)(S_{13-1} + b_{13-1})$$

$$S_{13} = 83.425,71$$

2. Nilai Pemulusan trend

$$b_{13} = \beta \times (S_{13} - S_{13-1}) + (1 - \beta) b_{13-1}$$

$$b_{13} = 1.502,94$$

3. Nilai Pemulusan musiman

$$I_{13} = \gamma \frac{X_{13}}{S_{13}} + (1 - \gamma)I_{13-12}$$

$$I_{13} = 1,0848$$

Untuk menghitung nilai pemulusan level, trend dan musiman selanjutnya dilakukan dengan cara yang sama.

Nilai Pemulusan Aditif

1. Nilai Pemulusan Level

$$S_{13} = \alpha(X_{13} - I_{13-12}) + (1 - \alpha)(S_{13-1} + b_{13-1})$$

$$S_{13} = 74.922,34$$

2. Nilai Pemulusan trend

$$b_{13} = \beta \times (S_{13} - S_{13-1}) + (1 - \beta) b_{13-1}$$

$$b_{13} = 1.668,55$$

3. Nilai Pemulusan musiman

$$I_{13} = \gamma(X_{13} - S_{13}) + (1 - \gamma)I_{13-12}$$

$$I_{13} = 10.798,99$$

Untuk menghitung nilai pemulusan level, trend dan musiman selanjutnya dilakukan dengan cara yang sama.

Model dan Nilai Peramalan untuk Multiplikatif dan aditif

Model dan Nilai Peramalan Multiplikatif

Kemudian akan dilakukan peramalan data pelatihan pada saat $t = 13$ sampai dengan $t = 72$ untuk Aditif

1. Periode peramalan $t = 13$

$$F_{13} = (S_{12} + b_{12} \times m)I_{12-12+1}$$

$$F_{13} = 60.857,28$$

Untuk menghitung nilai peramalan data pelatihan selanjutnya dilakukan dengan cara yang sama. Kemudian dilakukan peramalan data pengujian bulan Januari 2022 – Desember 2022 dengan model pada waktu ke $t = 72$ untuk ($m = 1, 2, \dots, 12$) sebagai

berikut : $F_{72+m} = (112.566,96 + 1.502,94 \times m) 0,7339$

2. Periode peramalan $t = 73$

$$F_{72+1} = (112.566,96 + 1.502,94 \times 1) 0,7339$$

$$F_{73} = 83.715,90$$

Untuk menghitung nilai peramalan data pengujian selanjutnya dilakukan dengan cara yang sama.

Model dan Nilai Peramalan Aditif

Kemudian akan dilakukan peramalan data pelatihan pada saat $t = 13$ sampai dengan $t = 72$ untuk Aditif

1. Periode peramalan $t = 13$

$$F_{13} = S_{12} + b_{12} \times m + I_{12-12+1}$$

$$F_{13} = 61.032,94$$

Untuk menghitung nilai peramalan data pelatihan selanjutnya dilakukan dengan cara yang sama. Kemudian dilakukan peramalan data pengujian bulan Januari 2022 – Desember 2022 dengan model pada waktu ke $t = 72$ untuk ($m = 1, 2, \dots, 12$) sebagai berikut : $F_{72+m} = 95.728,66 + 539,58 \times m + (-17.375,49)$

2. Periode peramalan $t = 73$

$$F_{72+1} = 95.728,66 + 539,58 \times 1 + (-17.375,49)$$

$$F_{73} = 78.892,75$$

Untuk menghitung nilai peramalan data pengujian selanjutnya dilakukan dengan cara yang sama.


Pengukuran ketepatan peramalan *Holt Winter Exponential Smoothing*

Pengukuran ketepatan peramalan untuk kedua metode menghasilkan RMSE sebagai berikut:

Tabel 3. Nilai Pengukuran Ketepatan Peramalan Multiplikatif dan Aditif

Metode	RMSE Pengujian
Aditif	40.029,56
Multiplikatif	54.550,17

Analisis Metode *Neural Network Autoregression* Menentukan *Input*



Gambar 4. Pola PACF Produksi Cabai Besar

Berdasarkan pada gambar 4 dengan melihat pola PACF dapat terlihat pada lag 1, lag 3 dan lag 5 melewati garis signifikan artinya terdapat 5 lag *input* yang dapat digunakan dalam proses *Neural Network Autoregression*

Menentukan Lapisan Tersembunyi

Lapisan tersembunyi dapat ditentukan secara tentatif melalui aturan *rule of thumb* untuk memvariasikan nilai k dengan persamaan (4) sebagai berikut :

Tabel 4. Lapisan tersembunyi NNAR


Konstanta γ	Nilai k
2	7
3	5
4	4
5	3

Proses Pelatihan Jaringan

Data produksi cabai besar yang akan digunakan untuk mendapatkan model dalam proses pelatihan yaitu data dari bulan Januari 2016 sampai Desember 2021. Sedangkan untuk data pada bulan Januari 2022 sampai Desember 2022 digunakan pada pengujian untuk melihat keakuratan model. Adapun pembentukan jaringan yang digunakan dalam proses pelatihan untuk meramalkan produksi cabai besar yaitu menggunakan model tentatif dilambangkan sebagai NNAR (p,k). *Input* dilambangkan dengan p dan k sebagai lapisan tersembunyi. Setelah mendapatkan *input* dan menentukan lapisan tersembunyi dengan memvariasikan nilai k terdapat 4 model *trial and error* yang akan dilakukan proses pelatihan yaitu NNAR (5,7), NNAR (5,5), NNAR (5,4) dan NNAR (5,3). Model yang terpilih adalah model yang memiliki nilai akurasi paling kecil yaitu dengan melihat nilai RMSE pada setiap model. Model tersebut menunjukkan kemungkinan model yang optimal untuk dapat dilakukan peramalan produksi cabai besar. Sebanyak 4 model yang akan dicoba untuk mencari model yang memiliki nilai RMSE terkecil. Pada proses pelatihan untuk setiap model pemberian nilai awal bobot, nilai awal bias, melakukan perhitungan *error* pada bobot jaringan, perubahan bobot, pemberhentian proses iterasi dan mendapatkan model matematis dalam algoritma *backpropagation* menggunakan *software R Studio* untuk mendapatkan hasil yang optimal.

Model dan Pengukuran Ketepatan Peramalan NNAR

Berdasarkan proses pelatihan melalui *software R Studio* dengan 4 model *trial and error* diperoleh nilai RMSE terkecil yaitu model NNAR (5,7). Dengan arsitektur sebagai berikut :



Gambar 5. Arsitektur Pelatihan Jaringan Model NNAR (5,7)

Dengan model tersebut menghasilkan RMSE Pengujian sebesar 39.490,91.

Perbandingan Ketepatan Peramalan

Untuk meramalkan periode kedepan diperlukan metode terbaik. Berdasarkan analisis kedua metode yaitu *Neural Network Autoregression* dan *Holt Winter Exponential Smoothing* diperoleh perbandingan sebagai berikut :

Tabel 5. Perbandingan Ketepatan Peramalan

Metode		RMSE Pengujian
Holt Winter Exponential Smoothing	Multiplikatif	54.550,17
	Aditif	40.029,56
Neural Network Autoregression		39.490,91

Peramalan m Periode kedepan

Peramalan m periode kedepan dilakukan dengan metode peramalan terbaik yang memiliki nilai ketepatan peramalan terkecil yaitu *Neural Network Autoregression*.

D. Kesimpulan

Berdasarkan pembahasan dalam penelitian ini, dapat disimpulkan bahwa

1. Berdasarkan perhitungan RMSE dalam setiap model peramalan, diperoleh nilai RMSE terkecil pada metode *Artificial Neural Networks*. Sehingga peramalan untuk m periode kedepan menggunakan metode *Artificial Neural Networks* dengan *Neural Network Autoregression* atau NNAR
2. Hasil dari peramalan yang dapat digunakan untuk memperkirakan produksi cabai besar di Kabupaten Garut Bulan Januari 2023 – Desember 2023 agar produksi dapat tercukupi dalam setiap bulannya yaitu pada bulan Januari 2023 sebesar 39.236,01 Kuintal, pada bulan Februari 2023 sebesar 62.485,96 Kuintal, pada bulan Maret 2023 sebesar 89.428,35 Kuintal, pada bulan April 2023 sebesar 116.605,41 Kuintal, pada bulan Mei 2023 Sebesar 116.785,68 Kuintal, pada bulan Juni 2023 sebesar 108.594,51 Kuintal, pada bulan Juli 2023 sebesar 81.626,00 Kuintal, pada bulan Agustus 2023 sebesar 87.220,70 Kuintal, pada bulan September 2023 sebesar 72.612,70 Kuintal, pada bulan Oktober 2023 sebesar 58.950,88 Kuintal, pada bulan November 2023 sebesar 40.120,61 Kuintal, pada bulan Desember 2023 sebesar 44.453,60 Kuintal.

Acknowledge

Puji dan syukur penulis panjatkan kehadiran Allah SWT karena berkat rahmat dan hidayah-Nya penulis dapat menyelesaikan penelitian ini. Terimakasih kepada ayah, ibu, keluarga yang selalu mendo'akan dan memberi dukungan. Terimakasih kepada Ibu Anneke Iswani Achmad, Dra.,M.Si. yang telah memberi bimbingan kepada penulis hingga penelitian ini selesai.

Daftar Pustaka

- [1] Aswi dan Sukarna. (2006). Analisis Deret Waktu : Teori dan Aplikasi. Makasar:
- [2] Setyawan, A (2021). Metode *Neural Network Autoregression* (NNAR) untuk Peramalan Data Runtun Waktu (Studi Kasus: Indeks Kualitas Udara Harian di Jakarta Pusat dan Jakarta Selatan). Yogyakarta : Universitas Gadjah Mada
- [3] Rosadi, D. (2011a). Analisis Ekonometrika & Runtun Waktu Terapan dengan R.
- [4] Makridakis, S., Wheelwright S.C., dan McGee V.E. (1999). Metode dan Aplikasi
- [5] Twumasi, C., & Twumasi, J. (2022). Machine learning algorithms for forecasting and backcasting blood demand data with missing values and outliers: A study of Tema General Hospital of Ghana. *International Journal of Forecasting*, 38(3), 1258–1277. <https://doi.org/10.1016/j.ijforecast.2021.10.008>
- [6] Makridakis, S., Wheelwright S.C., dan McGee V.E. (1999). Metode dan Aplikasi Peramalan Jilid 1 Edisi Revisi, Alih Bahasa: Hari Suminto. Jakarta: Binapura Aksara.
- [7] Pontoh, R. S., Toharudin, T., Ruchjana, B. N., Gumelar, F., Putri, F. A., Agisya, M. N.,

- & Caraka, R. E. (2022). Jakarta Pandemic to Endemic Transition: Forecasting COVID-19 Using NNAR and LSTM. *Applied Sciences* (Switzerland), 12(12). <https://doi.org/10.3390/app12125771>
- [8] Agnesya Risnandar, & Anneke Iswani Achmad. (2023). Pemodelan Generalized Space Time Autoregressive untuk Meramalkan Indeks Harga Konsumen. *Jurnal Riset Statistika*, 43–50. <https://doi.org/10.29313/jrs.v3i1.1792>