

PERBANDINGAN ANTARA *FEED FORWARD NEURAL NETWORK (FFNN)* DAN *SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (SARIMA)* UNTUK PERAMALAN DATA RUNTUN WAKTU TERAPAN

COMPARATION BETWEEN FEED FORWARD NEURAL NETWORK (FFNN) AND SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (SARIMA) IN FORECASTING SEASONAL TIME SERIES DATA

Dian Septiana¹, Melly Br Bangun²

¹Program Studi Statistika, Universitas Negeri Medan

²Program Studi Pendidikan Luar Sekolah, Universitas Negeri Medan

e-mail: [1dianseptiana@unimed.ac.id](mailto:dianseptiana@unimed.ac.id), [2mellybgn@unimed.ac.id](mailto:mellybgn@unimed.ac.id)

ABSTRAK

Pola musiman dalam data runtun waktu adalah pola periodik dan berulang yang disebabkan oleh faktor-faktor tertentu seperti cuaca, hari libur, pengulangan promosi, ataupun perubahan iklim ekonomi. Peramalan data yang baik sangat penting untuk melakukan pengambilan keputusan dalam sektor bisnis, seperti harga eceran, pemasaran, produksi dan sektor bisnis lainnya. Ada beberapa pendekatan yang dapat dilakukan untuk menganalisis data runtun waktu yang memiliki pola musiman atau tren. Diantaranya pendekatan klasik yang melakukan dekomposisi terhadap faktor musiman dan non musiman, lalu melakukan peramalan dengan asumsi-asumsi tertentu. Lalu ada juga pendekatan dengan menggunakan kecerdasan buatan, dalam hal ini digunakan jaringan syaraf tiruan dengan umpan maju (feed forward neural network) yang lebih fleksibel untuk digunakan sebagai alat peramalan data runtun waktu. Pada penelitian ini data yang digunakan adalah data dengan pola musiman reguler 12. Untuk data dengan pola seperti ini SARIMA (1,1,1)(0,1,1)¹²dengan MAPE 1,775% memberikan hasil lebih baik daripada FFNN 12-10-1 yang menghasilkan nilai MAPE 7,5226%.

Kata kunci: FFNN, SARIMA, peramalan, data runtun waktu, musiman

ABSTRACT

Seasonal patterns in time series data are periodic and recurring patterns caused by certain factors such as weather, holidays, repetition of promotions, or changes in the economic climate. Good data forecasting is very important for making decisions in the business sector, such as retail prices, marketing, production and other business sectors. There are several approaches that can be taken to analyze time series data that has a seasonal or trending pattern. Among them is the classical approach which decomposes seasonal and non-seasonal factors, then forecasts with certain assumptions. Then there is also an approach using artificial intelligence, in this case a more flexible feed-forward neural network is used as a tool for forecasting time series data. In this study the data used is data with a regular seasonal pattern 12. For data with a pattern like this SARIMA (1,1,1)(0,1,1)¹² with a MAPE of 1.775% gives better results than FFNN 12-10-1 which produces a MAPE value of 7.5226%.

Keywords: FFNN, SARIMA, peramalan, data runtun waktu, musiman

1. PENDAHULUAN

Pola musiman dalam data runtun waktu adalah pola periodik dan berulang yang disebabkan oleh faktor-faktor tertentu seperti cuaca, hari libur, pengulangan promosi, ataupun perubahan iklim ekonomi. Peramalan data yang baik sangat penting untuk melakukan pengambilan keputusan dalam sektor bisnis, seperti harga eceran, pemasaran, produksi dan sektor bisnis lainnya. Dalam bidang iklim dan cuaca, peramalan yang baik sangat dibutuhkan untuk kegunaan transportasi, prediksi bencana, dan lain sebagainya. Variasi musiman mungkin merupakan komponen utama dalam data runtun waktu musiman, tetapi tidak menutup kemungkinan pola tren juga turut serta di dalamnya. Data runtun waktu dengan tren dipandang sebagai data non-stasioner dan seringkali harus diubah menjadi data stasioner sebelum diolah dengan metode peramalan tertentu.

Ada beberapa pendekatan yang dapat dilakukan untuk menganalisis data runtun waktu yang memiliki pola musiman atau tren. Diantaranya adalah pendekatan klasik yang dilakukan untuk menghilangkan variasi tren dan musiman menggunakan metode penyesuaian tertentu. Misalnya metode dekomposisi yang membagi data runtun waktu ke dalam masing-masing komponennya yaitu tren, musiman, siklus, ataupun residu yang bersifat random, dan kemudian dilakukan peramalan terhadap nilai masing-masing dan komposisi tersebut secara terpisah (kecuali faktor random yang tidak dapat diduga) dan akhirnya menggabungkan kembali ramalan-ramalan tersebut. Jenis pendekatan klasik lain yang sudah sangat populer dan sering digunakan untuk analisis runtun waktu adalah model Box-Jenkins atau sering disebut dengan model *Autoregressive Integrated Moving Average* (ARIMA). Model ini melakukan *differencing* data terlebih dahulu untuk menghasilkan data runtun waktu yang stasioner, dan selanjutnya melakukan proses ARMA pada data hasil *differencing* tersebut. Untuk runtun waktu musiman telah diperkenalkan pula teknik ARIMA musiman atau dikenal dengan model *Seasonal Autoregressive Integrated Moving Average* (SARIMA). Salah satu prinsip utama dalam model SARIMA adalah bahwa model ini dibangun oleh proses linier. Model ARIMA mengasumsikan bahwa nilai di masa yang akan datang memiliki hubungan linier dengan nilai sekarang maupun sebelumnya.

Jaringan syaraf merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia tersebut. Istilah tiruan disini digunakan karena jaringan syaraf ini diimplementasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran. Ada beberapa tipe jaringan syaraf, namun demikian, hampir semuanya memiliki komponen-komponen yang sama. Seperti halnya otak manusia, jaringan syaraf tiruan juga terdiri dari beberapa neuron, dan ada hubungan antara neuron-neuron tersebut. Neuron-neuron tersebut akan mentransformasikan informasi yang diterima melalui sambungan keluarnya menuju ke neuron-neuron yang lain. Pada jaringan syaraf tiruan, hubungan ini dikenal dengan nama bobot. Informasi tersebut disimpan pada suatu nilai tertentu pada bobot tersebut. Jaringan syaraf tiruan (JST) merupakan permodelan data yang mampu dan kuat mewakili dan menangkap hubungan Input-Output yang komplek, karena kemampuannya untuk memecahkan beberapa masalah relatif mudah digunakan, ketahanan untuk mengimput data kecepatan untuk eksekusi, dan menginisialisasikan sistem yang rumit.

Prianda dan Widodo membandingkan model SARIMA dan ELM untuk meramalkan jumlah wisatawan mancanegara yang datang melalui bandara Ngurah Rai di Bali, diperoleh hasil bahwa SARIMA memberikan hasil peramalan yang lebih baik (Prianda & Widodo, 2021). Satria meramalkan penjualan produk di toko elektronik dan furnitur dengan menggunakan jaringan syaraf tiruan backpropagation dan menghasilkan performance peramalan yang cukup baik (Satria, 2021). Hasan menggunakan jaringan syaraf tiruan untuk meramalkan penjualan air minum dalam kemasan yang juga memberikan hasil yang cukup baik dengan nilai MAPE 6,88% (Hasan et al., 2019). Kumar Dubey dkk melakukan studi dan analisis terhadap SARIMA dan LSTM untuk meramalkan penggunaan energi, diperoleh hasil bahwa LSTM lebih menonjol dibandingkan SARIMA dengan menghasilkan MAE sebesar 0,23 (Kumar Dubey et al., 2021). Charandabi dan Kamyar mengevaluasi keakuratan FFNN dalam meramalkan harga *crypto currency*. Hasil

peramalannya baik hanya saja data memiliki nilai R-square yang rendah dan ditemukan kondisi heterokedastik (Charandabi & Kamyar, 2021). Fajari, dkk menggunakan SARIMA untuk meramalkan rata-rata harga beras yang merupakan komoditi makanan pokok masyarakat Indonesia, dan diperoleh model SARIMA (1,1,0)(0,0,3)¹² yang menghasilkan MSE sebesar 10356,71 (Fajari et al., 2021). Pada penelitian kali ini, JST yang dianggap memiliki kemampuan yang baik dalam melakukan peramalan data akan dibandingkan dengan SARIMA yang merupakan metode klasik dalam melakukan peramalan data runtun waktu musiman.

2. METODE PENELITIAN

Pada penelitian akan dilakukan peramalan data runtun waktu univariat yang memiliki pola musiman dengan menggunakan JST dan juga SARIMA. Data yang digunakan adalah data produksi susu (pon/sapi) yang merupakan data sekunder bulanan dari Januari 1962 - Desember 1975 dan diperoleh dari [kaggle.com](https://www.kaggle.com). Komputasi akan dilakukan dengan menggunakan MATLAB 2021 dan Eviews 6.

Feed Forward Neural Network (FFNN)/ Jaringan Syaraf Tiruan Umpan Maju

Tahapan metode feed forward neural network menggunakan algoritma backpropagation untuk langkah-langkah nya adalah (1) Melakukan pembagian data, yaitu data testing dan data training, (2) Menentukan input layer, (3) Menggunakan data training atau data latih, (4) Melakukan normalisasi data, (5) Membangun jaringan FFNN, (6) Neuron input menerima sinyal input dan menyebarkannya ke lapisan tersembunyi, (7) Neuron tersembunyi menjumlahkan bobot sinyal input dari lapisan input, menerapkan fungsi aktivasi untuk menghitung sinyal output, dan mengirimkan sinyal output dari fungsi aktivasi ke semua neuron dari lapisan output, (8) Neuron output menjumlahkan bobot sinyal input dari lapisan tersembunyi dan menerapkan fungsi aktivasi untuk menghitung sinyal output, (9) Melakukan denormalisasi data, (10) Menghitung MSE dan MAPE, dan (11) Peramalan dengan FFNN (Hapsari & Walid, 2021).

Algoritma ini memetakan data masukan dari lapisan masukan ke tujuan lapisan keluaran menggunakan neuron dari lapisan tersembunyi. Di lapisan tersembunyi, data input yang terkait dengan bobot ini kemudian diproses oleh fungsi aktivasi. Fungsi aktivasi yang akan digunakan adalah fungsi sigmoid yang dirumuskan sebagai

$$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad [1]$$

Fungsi sigmoid biner memiliki nilai range (0,1). Oleh karena itu, fungsi ini sering digunakan untuk jaringan syaraf yang membutuhkan nilai-nilai output yang terletak pada range (0,1). Karena data produksi susu yang digunakan pada penelitian kali ini tidak terletak pada range (0,1) maka pada tahap awal data akan dinormalisasi dahulu sehingga range datanya akan berubah dari 0,1 ke 0,9. Jika diketahui data asli adalah X maka data akan dinormalisasi dengan menggunakan rumus

$$X' = \frac{0,8(X - \min(X))}{\max(X) - \min(X)} + 0,1 \quad [2]$$

dimana

X' = data hasil normalisasi

X = data asli

$\max(X)$ = data maksimum

$\min(X)$ = data minimum

Selanjutnya, informasi yang diproses oleh lapisan tersembunyi digabungkan dengan bobot tersembunyi untuk neuron lapisan keluaran. Hasil yang diperoleh kemudian dibandingkan dengan data target sehingga diperoleh tingkat kesalahan (*error*). Apabila tingkat kesalahan yang diperoleh lebih kecil daripada tingkat kesalahan yang sebelumnya telah ditetapkan (*target error*),

maka proses perambatan akan berhenti. Namun apabila tingkat kesalahan masih lebih besar daripada tingkat kesalahan tetapan maka dilakukan proses perambatan balik dengan melakukan pembaharuan bobot.

Jaringan yang akan dibangun pada penelitian kali ini adalah jaringan dengan 12 input, beberapa pilihan jumlah lapisan tersembunyi, dan 1 output yang dilatih dengan metode umpan maju (*feed forward*) di Matlab 2021. Data runtun waktu ke-1 sampai ke-12 akan digunakan sebagai input dan dilatih untuk mendapatkan target pada data ke-13. Berikutnya data runtun waktu ke-2 sampai ke-13 akan dilatih untuk mendapatkan target pada data ke-14. Begitu seterusnya sampai data latih/ training selesai.

Seasonal Autoregressive Integrated Moving Average (SARIMA)

SARIMA merupakan pengembangan model ARIMA pada data runtun waktu yang memiliki pola musiman. Metode SARIMA ini dipopulerkan oleh George Box dan Gwilym Jenkins sekitar tahun 1970-an, model ini telah banyak dipelajari secara luas dan mengadopsi salah satu model yaitu ARIMA model. SARIMA juga merupakan metode analisis time series, sama seperti analisis tren, *moving average* atau *naive* (Durrach et al., 2018). Data runtun waktu musiman yaitu data runtun waktu yang mempunyai sifat berulang setelah beberapa periode waktu tertentu, misalnya satu tahun, satu bulan, triwulan, dan sebagainya. Oleh karena itu, data runtun waktu musiman mempunyai karakteristik yang ditunjukkan adanya korelasi yang kuat. Persamaan model SARIMA atau ARIMA musiman (p,d,q)(P,D,Q)^S dengan rumus sebagai berikut :

$$\phi_p(B)\phi_P(B^S)(1-B)^d(1-B^S)^D X_t = \theta_q(B)\theta_Q(B^S)e_t \quad [3]$$

dimana

X_t : nilai variabel X pada periode ke-t	θ_Q : parameter MA musiman
e_t : nilai error periode ke-t	S : jumlah periode musiman
ϕ_p : parameter AR nonmusiman	d : jumlah ordo differencing nonmusiman
ϕ_P : parameter AR musiman	D : jumlah ordo differencing musiman
θ_q : parameter MA nonmusiman	

Dalam menetapkan nilai p dan q dapat dibantu dengan mengamati pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). (Fahrudin & Sumitra, 2020)

Evaluasi Peramalan

Salah satu cara yang dapat digunakan untuk mengukur ketepatan model peramalan, yaitu nilai MAPE (Mean Absolute Percentage Error). MAPE adalah metode yang mengukur ketepatan nilai dugaan model yang dinyatakan dalam bentuk rata-rata persentase absolut kesalahan. Metode ini melakukan perhitungan perbedaan antara data asli dan data hasil peramalan perbedaan tersebut diabsolutkan, kemudian dihitung ke dalam bentuk persentase terhadap data asli. Hasil persentase tersebut kemudian diperoleh rata-ratanya (Prayudani et al., 2019).

Suatu model mempunyai kinerja sangat bagus jika nilai MAPE berada di bawah 10%, sedangkan jika nilai MAPE berada pada rentang 10% sampai 20% mempunyai kinerja bagus. Berikut adalah rumus persamaan dalam mencari nilai MAPE :

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{X_t - \hat{X}_t}{X_t} \right| \quad [4]$$


dimana

X_t : data aktual pada periode ke-t
 \hat{X}_t : data peramalan pada periode ke-t
 n : jumlah data yang digunakan

3. HASIL DAN PEMBAHASAN

Statistika Deskriptif

Data produksi susu (pon/sapi) dengan pola musiman 12 diperlihatkan pada gambar berikut



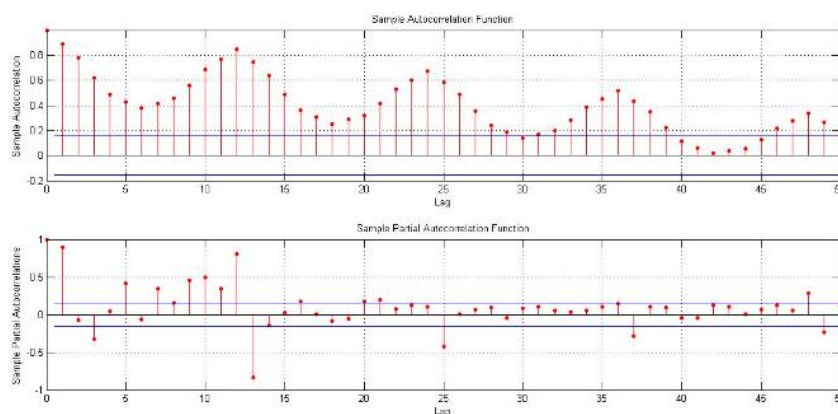
Gambar 1 Data Produksi Susu Sapi

Adapun statistika deskriptif dari data tersebut diberikan pada tabel berikut

Tabel 1 Statistika Deskriptif Data Produksi Susu

Statistika Deskriptif	Nilai
Banyak Data	168
Mean	754,7083
Simpangan Baku	102,2045
Data Tertinggi	969
Data Terendah	553

Uji Augmented-Dickey Fuller untuk mengetahui stasioneritas data dengan bantuan Software Eviews 6, memberikan nilai p-value sebesar 0,6682. Untuk taraf signifikansi 5% maka hasil tersebut menunjukkan bahwa data produksi susu bersifat non stasioner. Selanjutnya akan diidentifikasi faktor musiman dari data tersebut dengan menggunakan plot ACF dan PACF.



Gambar 2 Plot ACF dan PACF Data Produksi Susu

Dari gambar 2 dapat disimpulkan bahwa data memiliki faktor musiman dan tren yang kuat. Plot ACF menunjukkan bahwa data memiliki faktor musiman 12 bulan. Selanjutnya, akan ditampilkan perbandingan model JST dan SARIMA(p, d, q)(P, D, Q)¹² dalam peramalan data produksi susu yang memiliki pola musiman.

Feed Forward Neural Network (FFNN)

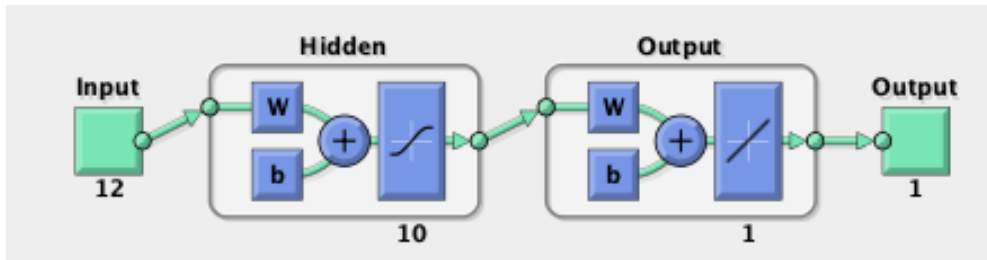
Data produksi susu akan dibagi menjadi data training dan data testing. Dari 168 data, sebanyak 158 atau 94% data merupakan data training, sedangkan 10 atau 6% data sisanya merupakan data testing. Data training digunakan untuk membangun model FFNN. Sedangkan data testing digunakan untuk menguji ketepatan peramalan dari model yang terbentuk. Hasil dari FFNN untuk 12 data input dan beberapa lapisan tersembunyi diperlihatkan pada tabel berikut :

Tabel 2 Hasil Evaluasi Peramalan Data Training dengan FFNN

Jumlah Lapisan Tersembunyi	MSE
10	$3,783 \times 10^{-4}$
8	$8,734 \times 10^{-4}$
5	$1,573 \times 10^{-3}$
20	$9,223 \times 10^{-4}$
7	$8,796 \times 10^{-4}$
9	$8,186 \times 10^{-4}$

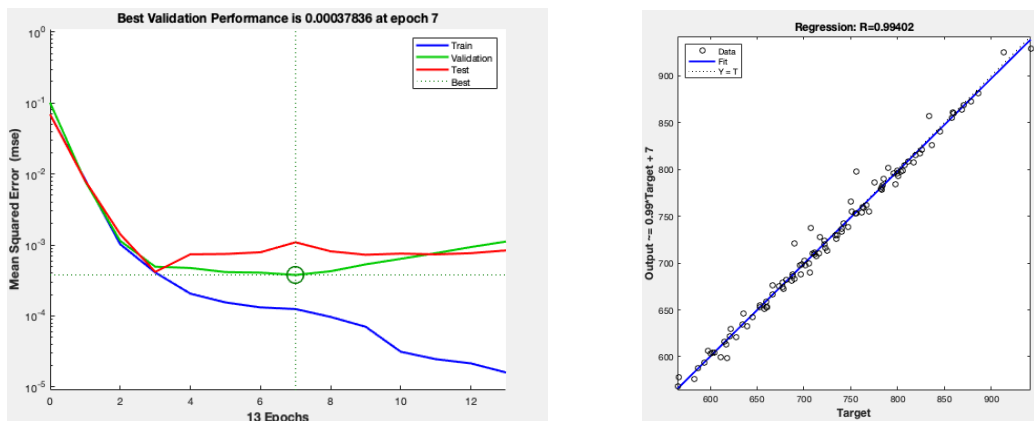
Dengan memperhatikan nilai MSE dari proses pelatihan FFNN, maka orde terbaik yang digunakan untuk meramalkan data runtun waktu musiman 12 periode adalah FFNN 12-10-1, yang artinya FFNN dengan 12 input dan 10 lapisan tersembunyi dengan MSE $3,783 \times 10^{-4}$. Struktur jaringan yang dimaksud adalah sebagai berikut :

Perbandingan Antara Feed Forward Neural Network (FFNN) Dan Seasonal Autoregressive Integrated Moving Average (SARIMA) Untuk Peramalan Data Runtun Waktu Terapan



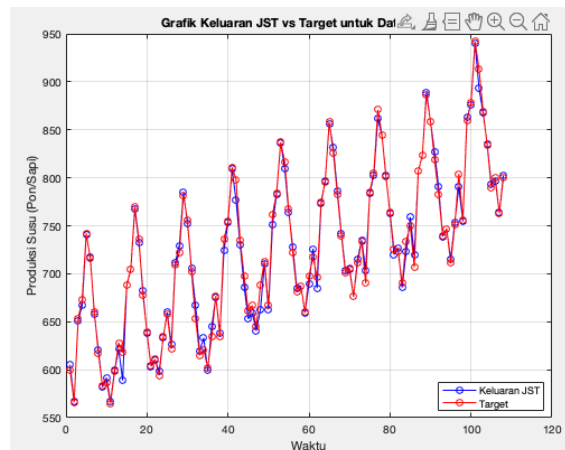
Gambar 3 Arsitektur Jaringan FFNN 12-9-1

RMSE optimal dan koefisien korelasi untuk data training ditunjukkan pada gambar berikut :



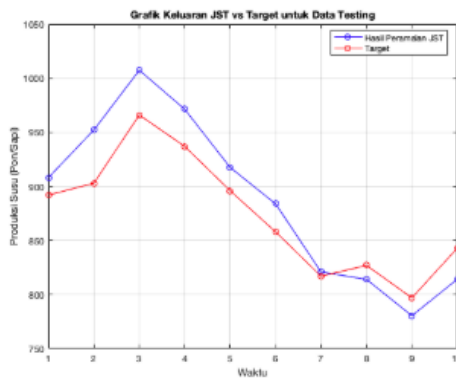
Gambar 4 MSE Optimal dan plot regresi data training dengan R= 0,99402

Perbandingan hasil peramalan FFNN dengan data asli akan diperlihatkan pada grafik berikut.



Gambar 5 Perbandingan Hasil Peramalan FFNN Data Training dengan Data Asli


FFNN optimal yang telah diperoleh pada pelatihan data training selanjutnya akan digunakan untuk melakukan fitting data untuk data testing yang diperoleh nilai MAPE sebesar 7,5226 %. Hal ini menunjukkan bahwa FFNN baik sekali digunakan untuk melakukan peramalan data runtun waktu dengan pola musiman. Hasil evaluasi peramalan FFNN 12-10-1 pada data testing ditunjukkan pada gambar berikut :



Gambar 6 Perbandingan Hasil Peramalan FFNN Data Testing dengan Data Asli

Seasonal Autoregressive Integrated Moving Average (SARIMA)

Pada bagian ini akan ditampilkan hasil analisis model SARIMA(p,d,q) (P, D, Q)^S untuk peramalan data produksi susu. Analisis dilakukan untuk beberapa orde model SARIMA. Orde terbaik akan ditentukan dengan membandingkan nilai AIC. Untuk melakukan peramalan dengan SARIMA, maka data harus memenuhi kondisi stasioner. Oleh karena itu, data produksi susu terlebih dahulu ditransformasi dengan menggunakan transformasi $\log(\text{data})$, kemudian di-differencing dan di-deseasonal, sehingga plot data produksi susu menjadi :



Gambar 7 Data Produksi Susu Setelah Proses Transformasi, Differencing dan Deseasonal

Hasil plot ACF dan PACF dari data yang sudah stasioner ditunjukkan oleh gambar berikut.

Sample (adjusted): 1963M02 1975M12
Included observations: 155 after adjustments

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
█	█	1	-0.213	-0.213	7.1490	0.008
		2	-0.011	-0.059	7.1672	0.028
		3	0.096	0.095	8.9300	0.035
		4	-0.126	-0.093	11.204	0.024
		5	-0.095	-0.146	12.672	0.027
		6	-0.024	-0.096	12.768	0.047
		7	0.115	0.113	14.948	0.037
		8	0.047	0.114	15.313	0.053
		9	-0.051	-0.041	15.750	0.072
		10	0.128	0.064	18.491	0.047
		11	-0.008	0.048	18.502	0.071
█	█	12	-0.436	-0.420	58.878	0.000
		13	0.183	-0.002	56.640	0.000
		14	-0.072	-0.020	57.543	0.000
		15	-0.050	0.000	57.972	0.000
		16	0.027	-0.112	58.098	0.000
		17	0.119	0.037	60.580	0.000


Gambar 8 Plot ACF dan PACF Preprocessing Data Produksi Susu

Identifikasi model dilakukan setelah dipastikan bahwa data telah stasioner. Model SARIMA biasanya dinotasikan SARIMA (p,d,q)(P,D,Q)^S. Dalam hal ini p dan q adalah urutan masing-

Perbandingan Antara Feed Forward Neural Network (FFNN) Dan Seasonal Autoregressive Integrated Moving Average (SARIMA) Untuk Peramalan Data Runtun Waktu Terapan

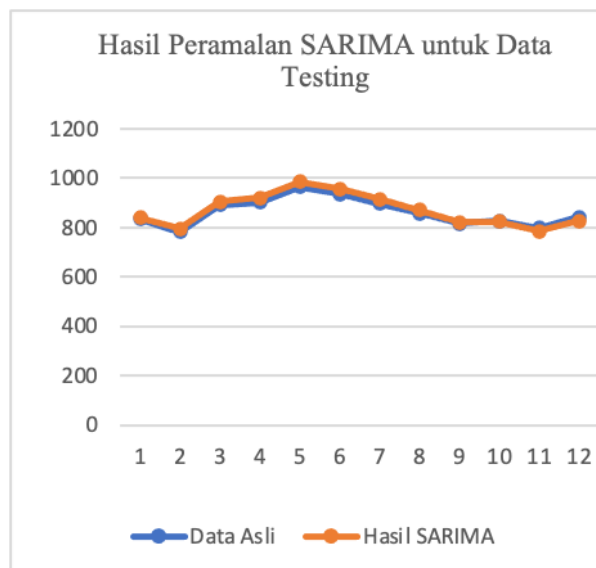
masing AR dan MA, dimana d adalah urutan pembeda/ *differencing*. Berdasarkan plot ACF dan PACF seperti pada Gambar 7. dapat dilakukan identifikasi model awal. Untuk model nonmusiman dilihat dari plot PACF terdapat lag yang keluar garis batas yaitu lag ke-1 sehingga nilai $p = 1$, dan plot ACF ada lag yang melewati garis batas yaitu lag 1, sehingga nilai $q = 1$. Differencing nonmusiman dilakukan sebanyak 1 kali, maka $d = 1$. Sedangkan untuk model musiman, pada plot PACF terdapat lag ke-12 yang keluar melewati batas, maka nilai $P = 1$. Pada plot ACF lag ke-12 melewati garis batas, sehingga nilai $Q = 1$. Differencing musiman dilakukan sebanyak 1 kali, maka nilai $D = 1$. Dengan demikian model awal yang terbentuk yaitu SARIMA $(1,1,1)(1,1,1)^{12}$. Apabila model awal telah diperoleh, kemudian dilakukan pengembangan model atau dimodifikasi menjadi beberapa model dan dilakukan estimasi model parameter. Maka diperoleh model yang parameternya signifikan dan memiliki nilai AIC terkecil yaitu model SARIMA $(1,1,1)(1,1,0)^{12}$.

Model SARIMA yang baik adalah model yang menghasilkan peramalan dengan kondisi residu/ error yang baik. Gambar di bawah ini menunjukkan bahwa model SARIMA $(1,1,1)(1,1,0)^{12}$ menghasilkan residu/error yang berdistribusi normal dan tidak ber autokorelasi.



Gambar 9 Plot ACF dan PACF Residu dan Histogram Residu

Perbandingan hasil peramalan SARIMA dengan data testing memberikan nilai MAPE 1,775 % yang diperlihatkan pada gambar berikut



4. KESIMPULAN

Kesimpulan yang dapat diambil dari penelitian ini diuraikan sebagai berikut.

1. SARIMA (1,1,1)(0,1,1)¹² dengan MAPE 1,775 % memberikan hasil peramalan yang lebih baik daripada FFNN 12-10-1 dengan MAPE 7,5226 % untuk data runtun waktu dengan pola musiman yang teratur yaitu 12
2. Untuk penelitian berikutnya dapat dilakukan peramalan untuk data musiman yang tidak teratur dengan menggunakan model klasik ataupun kecerdasan buatan. Dapat ditelusuri manakah yang mampu menangkap pola data dengan lebih baik.
3. Hibrid atau campuran antara model peramalan klasik dengan yang lainnya juga sangat bisa dipertimbangkan untuk dapat dilakukan demi menghasilkan peramalan yang lebih baik.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Prodi Statistika dan Prodi Pendidikan Luar Sekolah Universitas Negeri Medan sebagai lembaga yang menaungi penulis sehingga dapat menyelesaikan tulisan ini dengan baik.

DAFTAR PUSTAKA

- Charandabi, S. E., & Kamyar, K. (2021). Using A Feed Forward Neural Network Algorithm to Predict Prices of Multiple Cryptocurrencies. *European Journal of Business and Management Research*, 6(5), 15–19. <https://doi.org/10.24018/ejbmr.2021.6.5.1056>
- Durrah, F. I., Yulia, Y., Parhusip, T. P., & Rusyana, A. (2018). Peramalan Jumlah Penumpang Pesawat Di Bandara Sultan Iskandar Muda Dengan Metode SARIMA (Seasonal Autoregressive Integrated Moving Average). *Journal of Data Analysis*, 1(1), 1–11. <https://doi.org/10.24815/jda.v1i1.11847>
- Fahrudin, R., & Sumitra, I. (2020). PERAMALAN INFLASI MENGGUNAKAN METODE SARIMA DAN SINGLE EXPONENTIAL SMOOTHING (STUDI KASUS: KOTA BANDUNG). *Majalah Ilmiah UNIKOM*, 17(2). <https://doi.org/10.34010/miu.v17i2.3180>
- Fajari, D. A., Abyantara, M. F., & Lingga, H. A. (2021). PERAMALAN RATA-RATA HARGA BERAS PADA TINGKAT PERDAGANGAN BESAR ATAU GROSIR INDONESIA DENGAN METODE SARIMA (SEASONAL ARIMA). *JURNAL AGRIBISNIS TERPADU*, 14(1), 88. <https://doi.org/10.33512/jat.v14i1.11460>
- Hapsari, N. W., & Walid. (2021). Pemodelan ARIMAX dan FFNN, Serta Hybrid ARIMAX-FFNN Untuk Meramalkan Produksi Padi di Provinsi Jawa Tengah. *Unnes Journal of Mathematics*, 10, 12–21.
- Hasan, N. F., Kusri, K., & Fatta, H. Al. (2019). Analisis Arsitektur Jaringan Syaraf Tiruan Untuk Peramalan Penjualan Air Minum Dalam Kemasan. *Jurnal Rekayasa Teknologi Informasi (JURTI)*, 3(1), 1. <https://doi.org/10.30872/jurtti.v3i1.2290>
- Kumar Dubey, A., Kumar, A., García-Díaz, V., Kumar Sharma, A., & Kanhaiya, K. (2021). Study and analysis of SARIMA and LSTM in forecasting time series data. *Sustainable Energy Technologies and Assessments*, 47, 101474. <https://doi.org/10.1016/j.seta.2021.101474>
- Prayudani, S., Hizriadi, A., Lase, Y. Y., Fatmi, Y., & Al-Khowarizmi. (2019). Analysis Accuracy Of Forecasting Measurement Technique On Random K-Nearest Neighbor (RKNN) Using MAPE And MSE. *Journal of Physics: Conference Series*, 1361(1), 012089. <https://doi.org/10.1088/1742-6596/1361/1/012089>
- Prianda, B. G., & Widodo, E. (2021). PERBANDINGAN METODE SEASONAL ARIMA DAN EXTREME LEARNING MACHINE PADA PERAMALAN JUMLAH WISATAWAN MANCANEGARA KE BALI. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 15(4), 639–650. <https://doi.org/10.30598/barekengvol15iss4pp639-650>
- Satria, W. (2021). JARINGAN SYARAF TIRUAN BACKPROPAGATION UNTUK PERAMALAN PENJUALAN PRODUK (STUDI KASUS DI METRO ELECTRONIC DAN FURNITURE). *Djtechno: Jurnal Teknologi Informasi*, 1(1), 14–19. <https://doi.org/10.46576/djtechno.v1i1.966>