

PENAMBAHAN METODE NEURAL NETWORK DALAM PEMODELAN GSTAR-SUR UNTUK MENGATASI KASUS NON LINIER PADA PERAMALAN DATA CURAH HUJAN

Atiek Iriany

Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Brawijaya, Malang, Indonesia

Email : atiekiriany@ub.ac.id

Adji Achmad Rinaldo Fernandes

Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Brawijaya, Malang, Indonesia

Wigbertus Ngabu

Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Brawijaya, Malang, Indonesia

Achmad Efendi

Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Brawijaya, Malang, Indonesia

Henida Ratna Ayu Putri

Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Brawijaya, Malang, Indonesia

Danang Ariyanto

Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Brawijaya, Malang, Indonesia

Abstrak

Salah satu model peramalan yang dapat menggabungkan unsur spasial (spatial) dan temporal (time) adalah Generalized Space Time Autoregressive (GSTAR). Pendugaan parameter yang digunakan adalah Seemingly Unrelated Regression (SUR). Peramalan iklim pada tanaman hortikultura pada masa kini sulit untuk diprediksi karena memiliki pola dan karakteristik yang sulit diidentifikasi dan dapat disebut aktivitas non linier. Unsur non linier ini dapat ditangkap oleh metode neural network. Penelitian ini ingin mengetahui hasil peramalan curah hujan pada 6 wilayah di Tengger menggunakan model GSTAR dengan pendugaan parameter menggunakan metode SUR dan digabungkan dengan neural network agar hasil peramalan yang lebih akurat. Data yang digunakan dalam penelitian ini adalah data curah hujan enam lokasi di wilayah Tengger, yakni Ngadirejo, Puspo, Wonokitri, Argosari, Ngadas, dan Wonokerto. Model yang tepat dalam melakukan peramalan pada data curah hujan pada 6 lokasi Tengger adalah model GSTAR (1,2,3,4,5,6,7,36(1)) *Backpropagation Neural Network* (96-120-6).

Kata Kunci: GSTAR, SUR, Neural Network, Curah Hujan

PENDAHULUAN

Peramalan adalah proses perkiraan atau prediksi nilai atau kejadian di masa mendatang berdasarkan data dan informasi yang ada mengenai peristiwa atau fenomena di masa lalu atau saat ini (Wardah & Iskandar, 2017). Tujuan utama dari peramalan adalah untuk mengestimasi apa yang akan terjadi di masa depan agar dapat membuat rencana dan strategi yang tepat untuk menghadapi perubahan atau situasi yang akan datang. Pada saat melakukan peramalan seperti curah hujan tidak hanya diperlukan unsur waktu tetapi juga unsur spasial. Metode peramalan yang menggabungkan unsur spasial (spatial) dan temporal (time) untuk memodelkan hubungan

antara berbagai variabel iklim di lokasi dan waktu yang berbeda adalah Generalized Space Time Autoregressive (GSTAR) (Fransiska *et al.*, 2020). Metode ini memperhitungkan interaksi dan keterkaitan antara berbagai variabel iklim dalam wilayah yang lebih luas dan rentang waktu yang lebih panjang.

Metode pendugaan parameter yang biasa digunakan dalam pemodelan ruang dan waktu adalah metode OLS. Tetapi, metode tersebut memiliki kekurangan yakni residual model yang saling berkorelasi sehingga menghasilkan nilai duga yang tidak efisien (Pramesthi & Saputro, 2023). Oleh karena itu, perlu dilakukan metode pendugaan yang lain yakni Seemingly Unrelated

Regression (SUR). Metode ini mampu mengatasi adanya korelasi antar sisaan melalui matriks ragam peragam sisaan dalam model sehingga akan menghasilkan estimasi yang lebih baik dan valid (Setiawan *et al.*, 2016).

Peramalan iklim sangat diperlukan oleh petani untuk penentuan kalender tanam, salah satunya adalah tanaman hortikultura. Tanaman hortikultura merupakan tanaman pertanian yang berhubungan dengan budaya yakni sayuran, buah, tanaman obat-obatan, beserta tanaman hias (Mogea *et al.*, 2021). Tanaman hortikultura adalah tanaman dengan komoditas unggulan yang dapat meningkatkan pertumbuhan ekonomi serta pendapatan masyarakat. Peramalan iklim pada tanaman hortikultura pada masa kini sulit untuk diprediksi karena memiliki pola dan karakteristik yang sulit diidentifikasi dan dapat disebut aktivitas non linier. Unsur non linier ini dapat ditangkap oleh metode neural network (Sari & Maulidany, 2020). Neural network adalah teknik pembelajaran mesin yang digunakan untuk mengatasi kompleksitas dan non-linieritas dalam data iklim (Rizal & Hartati, 2007). Jaringan saraf tiruan (neural network) dapat mengidentifikasi pola dan hubungan non-linier yang tidak dapat ditangkap oleh metode statistik lainnya, sehingga memungkinkan peramalan iklim yang lebih akurat dan presisi. Penelitian terdahulu telah dilakukan oleh Rizal & Hartati (2007) yang melakukan penelitian penggabungan metode peramalan *Extended Kalman Filter* dengan *neural network*. Penelitian ini ingin mengetahui hasil peramalan curah hujan pada 6 wilayah di Tengger menggunakan model GSTAR dengan pendugaan parameter menggunakan metode SUR dan digabungkan dengan neural network agar hasil peramalan yang lebih akurat.

TINJAUAN PUSTAKA

Eksplorasi Data

Eksplorasi data adalah langkah untuk memahami bagaimana keadaan data sebelum dilakukan praproses. Pemahaman terhadap data yang dilakukan sebelumnya dapat digunakan untuk menentukan teknik-teknik praproses yang dibutuhkan. Eksplorasi data memiliki tujuan untuk memberikan deskripsi secara umum

terhadap data curah hujan yang didapatkan pada titik tertentu (Fransiska *et al.*, 2019). Beberapa macam eksplorasi data adalah sebagai berikut.

a. Statistika Deskriptif

Statistika deskriptif adalah cabang statistika yang bertujuan untuk menggambarkan, meringkas, dan menganalisis data secara deskriptif (Saptono & Harsoyo, 2022). Metode statistika deskriptif digunakan untuk mengidentifikasi pola, hubungan, dan karakteristik dari suatu kumpulan data tanpa melakukan generalisasi atau inferensi terhadap populasi yang lebih besar. Contoh statistika deskriptif yang digunakan adalah penghitungan rata-rata, median, modus, standar deviasi, dan distribusi frekuensi. Tujuan dari statistika deskriptif adalah untuk memberikan gambaran yang lebih jelas dan ringkas tentang data yang ada.

b. Visualisasi Data

Visualisasi data adalah proses menggunakan elemen visual seperti diagram, grafik, atau peta untuk merepresentasikan data (Madyatmadja *et al.*, 2022). Visualisasi data menerjemahkan yang kompleks, bervolume tinggi, atau numerik menjadi representasi visual yang lebih mudah diproses. Alat visualisasi data meningkatkan dan mengotomatiskan proses komunikasi visual untuk mendapatkan akurasi dan detail. Visualisasi data dapat berupa grafik, diagram, peta, infografis, atau representasi visual lainnya. Tujuan utama dari visualisasi data adalah membuat data lebih mudah dipahami dan memberikan wawasan yang lebih dalam tentang data tersebut. Salah satu visualisasi data adalah plot data. Plot data adalah jenis visualisasi data tertentu yang menggambarkan distribusi dan pola dalam data numerik. Plot data lebih terfokus pada pemetaan nilai data pada sumbu x dan y atau sumbu koordinat lainnya. Plot data digunakan untuk menunjukkan hubungan antara dua atau lebih variabel, atau untuk menunjukkan bagaimana data berubah dari waktu ke waktu. Plot data membantu mengungkapkan korelasi, outlier, pola linier, atau tren dalam data (Pamungkas & Wibowo, 2019). Ini memungkinkan kita untuk mengenali dan menggambarkan hubungan antara variabel-variabel tertentu dengan cara yang lebih visual.

Model Generalized Space Time Autoregressive (GSTAR)

Generalized Space Time Autoregressive (GSTAR) model yang relatif baru untuk data *time series*. Ruchjana (2002) mengemukakan bahwa GSTAR merupakan generalisasi dan perluasan model *Space Time Autoregressive* (STAR) (Pfeifer, 1990). Model GSTAR adalah bentuk spesifik dari model VAR (*Vector Autoregressive*), ini menunjukkan dependensi linier *space-time*. Perbedaan utama adalah pada *spatial dependent* dan bobot matriks. Model GSTAR lebih realistis karena pada kenyataannya lebih banyak ditemui model dengan parameter model berbeda untuk lokasi yang berbeda (Wutsqa dan Suhartono, 2009).

Model GSTAR orde p dan spasial orde $\lambda_1, \lambda_2, \dots, \lambda_p$, GSTAR ($p\lambda_1, \lambda_2, \dots, \lambda_p$) dirumuskan sebagai berikut (Borovkova, Lopuhaa and Nurani, 2002):

$$Z_t = \mu(t) + \sum_{k=1}^p \left[\Phi_{k0} + \sum_{m=1}^{\lambda_k} \Phi_{kl} w^{(l)} \right] Z_{(t-p)} + \varepsilon(t) \quad (2.1)$$

di mana:

$$\Phi_{k0} = \text{diag}(\phi_{k0}^{(1)}, \dots, \phi_{k0}^{(N)}) \text{ dan}$$

$$\Phi_{kl} = \text{diag}(\phi_{kl}^{(1)}, \dots, \phi_{kl}^{(N)})$$

Pembobot dipilih sedemikian hingga $w_{ii} = 0$ dan $\sum_{i \neq j} w_{ij} = 1$

Sebagai contoh, model GSTAR (1₁) untuk n lokasi yang berbeda adalah sebagai berikut:

$$Z(t) = \mu(t) + [\Phi_{01} + \Phi_{11}W] Z(t-1) + \varepsilon(t) \quad (2.2)$$

Pendugaan Parameter Model GSTAR-SUR Sistem Persamaan Seemingly Unrelated Regression (SUR)

Seemingly Unrelated Regression (SUR) merupakan suatu persamaan yang pendugaan parameternya menggunakan *General Least Square* (GLS). Iriany (2013) menjelaskan bahwa GLS adalah estimator koefisien regresi yang memperhatikan adanya hubungan residual antar persamaan, dengan nilai residual diperoleh dari pendugaan *Ordinary Least Square* (OLS) yang nantinya digunakan dalam perhitungan untuk menduga koefisien regresi pada sistem persamaan SUR. Model SUR dengan M persamaan dinyatakan dengan

$$y_i = X_i \beta_i + \varepsilon_i, \quad i = 1, \dots, N \quad (2.3)$$

di mana y_i merupakan vektor berukuran $R \times 1$, X_i berukuran $R \times k_i$ dan β_i vektor berukuran $k_i \times 1$. Sistem persamaan 2.3 dapat dituliskan dalam bentuk matriks berikut :

$$\begin{pmatrix} y_1 & y_2 & \dots & y_N \end{pmatrix} = \begin{pmatrix} X_1 & 0 & \dots & 0 \\ \vdots & \dots & 0 & 0 \\ \vdots & \dots & \vdots & \vdots \\ 0 & \dots & 0 & X_N \end{pmatrix} \begin{pmatrix} \beta_1 & \beta_2 & \dots & \beta_N \end{pmatrix} + \begin{pmatrix} \varepsilon_1 & \varepsilon_2 & \dots & \varepsilon_N \end{pmatrix} = X\beta + \varepsilon$$

dengan

y, ε : vektor berukuran $(NT \times 1)$

X : matriks berukuran $(NT \times N(K+1))$

β : vektor berukuran $(N(K+1) \times 1)$

(Kmenta, 1990).

Menurut Greene (2002), persamaan (2.3) merupakan model SUR dengan asumsi $E[X_1, X_2, \dots, X_N] = 0$ dan $E[X_1, X_2, \dots, X_N] = \Omega$ dengan Ω adalah matriks ragam-peragam.

Metode GLS menggunakan ragam galat, yaitu $\text{Cov}(\varepsilon) = E(\varepsilon\varepsilon') = \sigma^2 \Sigma = \Omega$

Matriks Ω menggambarkan hubungan galat dengan:

$$\Omega = E(\varepsilon\varepsilon') = E[[e_1 \ e_2 \ \dots \ e_N][e_1 \ e_2 \ \dots \ e_N]']$$

$$\Omega = E(\varepsilon\varepsilon')$$

$$= [E(e_1e_1') \ E(e_1e_2') \ \dots \ E(e_1e_N') \ E(e_2e_1') \ E(e_2e_2') \ \dots \ E(e_2e_N') \\ \vdots \ E(e_Ne_1') \ E(e_Ne_2') \ \vdots \ \dots \ E(e_Ne_N')]$$

karena $E(\varepsilon_i\varepsilon_j') = \sigma_{ij}I_T$ maka:

$$\Omega =$$

$$[\sigma_{11}I_{NT} \ \sigma_{12}I_{NT} \ \dots \ \sigma_{1N}I_{NT} \ \sigma_{21}I_{NT} \ \sigma_{22}I_{NT} \ \dots \ \sigma_{2N}I_{NT} \ \vdots \\ \sigma_{N1}I_{NT} \ \vdots \ \sigma_{N2}I_{NT} \ \vdots \ \dots \ \vdots \ \sigma_{NN}I_{NT}] = \Sigma \otimes I_{NT}$$

$$\Sigma = [\sigma_{11} \ \sigma_{12} \ \dots \ \sigma_{1m} \ \sigma_{21} \ \sigma_{22} \ \dots \ \sigma_{2m} \ \vdots \ \sigma_{m1} \ \vdots \\ \sigma_{m2} \ \vdots \ \dots \ \vdots \ \sigma_{mm}] \quad (2.4)$$

dengan I_{NT} merupakan matriks identitas berukuran $(NT \times NT)$ dan Σ merupakan matriks yang berukuran $(N \times N)$ dengan σ_{ij} adalah ragam galat dari masing-masing persamaan untuk $i=j$ dan merupakan kovarian galat antar persamaan untuk $i \neq j$.

Pendugaan parameter model diperoleh dengan menduga parameter β dalam persamaan berikut.

$$\varepsilon'_* \varepsilon_* = \varepsilon' \Omega^{-1} \varepsilon \\ = Y' \Omega^{-1} Y - 2Y' \Omega^{-1} X \beta + \beta' X' \Omega^{-1} X \beta \quad (2.5)$$

Persamaan (2.5) diturunkan terhadap β dan disamakan dengan nol.

Sehingga menjadi:

$$(X' \Omega^{-1} X) \hat{\beta} = X' \Omega^{-1} Y \\ (X' \Omega^{-1} X)^{-1} (X' \Omega^{-1} X) \hat{\beta} = (X' \Omega^{-1} X)^{-1} X' Y \\ I \hat{\beta} = (X' \Omega^{-1} X)^{-1} X' \Omega^{-1} Y \\ \hat{\beta} = (X' \Omega^{-1} X)^{-1} X' \Omega^{-1} Y \quad (2.6)$$

Penduga β untuk model GSTAR-SUR ($p1$) adalah sebagai berikut:

$$\hat{\beta} = (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}Y$$

$$= (X'(\hat{\Sigma}^{-1} \otimes I_{NT})X)^{-1}X'(\hat{\Sigma}^{-1} \otimes I_{NT})Y \quad (2.7)$$

GSTAR-SUR-NN

Jaringan Syaraf Tiruan atau Artificial Neural Network (NN) adalah teknik dalam ML yang menirukan syaraf manusia yang merupakan bagian fundamental dari otak (Ahmad, 2017). Struktur neural network terdiri dari unit-unit kecil yang disebut "neuron" atau "node" yang terhubung dalam lapisan-lapisan. Lapisan pertama disebut lapisan masukan (input layer), lapisan terakhir disebut lapisan keluaran (*output layer*), dan lapisan-lapisan di antaranya disebut lapisan tersembunyi (*hidden layers*). Setiap koneksi antara neuron-neuron memiliki "berat" (*weight*) yang mempengaruhi bagaimana informasi mengalir melalui jaringan. Selain itu, setiap neuron memiliki fungsi aktivasi yang digunakan untuk mengatur output neuron berdasarkan input dan bobotnya.

Proses pembelajaran neural network dilakukan dengan memberikan contoh data ke jaringan (data pelatihan) yang sudah memiliki label (misalnya, gambar kucing atau anjing). Jaringan ini mencoba untuk menyesuaikan bobotnya secara iteratif sehingga menghasilkan output yang sesuai dengan label yang benar. Ini dilakukan melalui metode yang disebut "propagasi mundur" (*backpropagation*), di mana kesalahan prediksi diukur dan kembali ke jaringan untuk mengoptimalkan bobotnya.

Pada penelitian ini, model neural network akan diterapkan pada sisaan model GSTAR- SUR. Input layer yang digunakan adalah sisaan model GSTAR-SUR. Hidden layer yang digunakan sebanyak 1 layer tetapi jumlah neuron yang digunakan dalam hidden layer berdasarkan nilai RMSE terkecil. Output layer yang digunakan sebanyak 4 variabel. Algoritma yang digunakan adalah algoritma *resilient backpropagation*.

METODE

Data yang digunakan dalam penelitian ini adalah data curah hujan enam lokasi di wilayah Tengger, yakni Ngadirejo, Puspo, Wonokitri, Argosari, Ngadas, dan Wonokerto. Periode data curah hujan dimulai tahun 2013 – 2023. Konsep

awal dalam penelitian ini adalah melakukan eksplorasi data curah hujan terlebih dahulu yakni dengan melihat statistika deskriptif berupa mean, simpangan baku, nilai minimum, dan nilai maksimum. Langkah selanjutnya adalah melakukan visualisasi data berupa plot data. Setelah didapatkan hasil dari eksplorasi dan visualisasi data, maka dilakukan peramalan pada data. Konsep peramalan menggunakan model GSTAR-SUR-NN yang kemudian akan dilakukan validasi pada keenam lokasi untuk menentukan model GSTAR-SUR-NN yang tepat untuk melakukan peramalan data curah hujan di Wilayah Tengger pada tahun 2013 – 2023. Bobot lokasi yang digunakan dalam penelitian ini adalah bobot lokasi normalisasi korelasi silang.

HASIL DAN PEMBAHASAN

Statistika Deskriptif

Statistika Deskriptif Data Curah Hujan di Wilayah Tengger

Penelitian yang telah berjalan berada di wilayah Tengger. Model ramalan curah hujan yang akan diterapkan pada alat *mini weather station* berdasarkan data curah hujan pada tahun sebelumnya di beberapa pos hujan lokasi wilayah Tengger. Deskripsi statistik digunakan untuk memudahkan melihat informasi mengenai data. Data yang digunakan dalam penelitian ini adalah data curah hujan bulanan di 6 lokasi pos hujan di wilayah Tengger selama periode tahun 2013-2023 (selama 10 tahun).

Tabel 4.1. Statistika Deskriptif Data Curah Hujan enam lokasi di Wilayah Tengger Bulan Januari 2013 – Juni 2023.

Lokasi	Rata-rata	Simpangan baku	Min	Maks
Ngadirejo	5.12	5.56	0	28.15
Puspo	6.29	6.80	0	36.05
Wonokitri	9.15	8.21	0	36.45
Argosari	9.20	7.18	0	36.18
Ngadas	9.60	9.29	0	53.80
Wonokerto	5.44	5.48	0	24.45

Tabel 4.1 menunjukkan rata-rata curah hujan, simpangan baku, curah hujan minimum dan curah hujan maksimum di masing-masing lokasi. Rata-rata curah hujan di wilayah Tengger berada di bawah 20 mm. Rata-rata curah hujan tertinggi

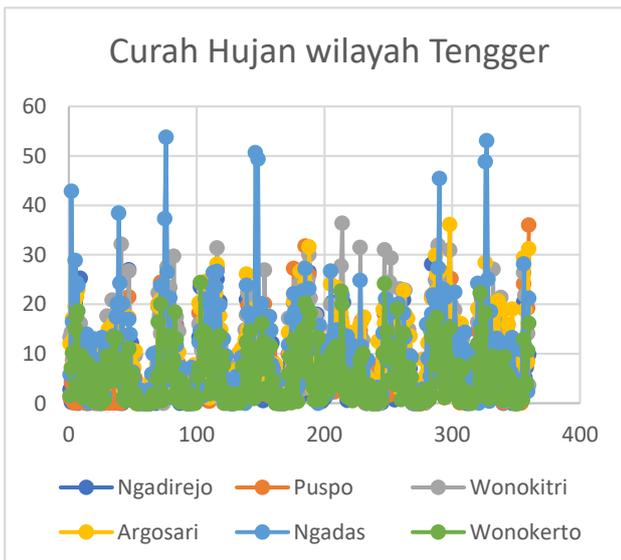
adalah di desa Ngadas sebesar 9.60 mm sedangkan rata-rata curah hujan terendah terdapat di desa Ngadirejo sebesar 5.12 mm.

Simpangan baku terbesar terdapat di daerah Ngadas yaitu sebesar 9.29 mm, artinya ada sebagian curah hujan di beberapa bulan yang berbeda dengan curah hujan di bulan-bulan lainnya atau berbeda dari rata-rata dengan dengan perbedaan sebesar 9.29 mm. Nilai Minimum curah hujan enam lokasi di wilayah Tengger sebesar 0 mm sehingga dapat dikatakan terdapat beberapa dasarian yang tidak terjadi hujan sama sekali. Hal ini dapat mengindikasikan telah memasuki musim kemarau. Pada musim penghujan curah hujan tertinggi yaitu pada titik maksimum di masing-masing daerah. Daerah yang memiliki curah hujan tertinggi pada musim penghujan adalah Ngadas sebesar 53.80 mm.

Plot Data

Langkah pertama yang harus dilakukan untuk melakukan pemodelan adalah membuat plot data.

Gambar 4.1 Plot data curah hujan pada masing-masing lokasi



Dari Gambar 4.1 dapat dilihat bahwa curah hujan di enam lokasi di wilayah Tengger sangat berfluktuatif. Plot menunjukkan dari keenam lokasi hampir memiliki fluktuasi curah hujan yang sama. Plot menunjukkan bahwa setiap bulan dalam tahun tertentu cenderung naik dan turun. Apabila dilihat pola data pertahun, curah hujan memiliki pola yang sama sehingga hal ini mengindikasikan bahwa adanya pola musiman.

Indeks gini

Indeks gini digunakan untuk melihat keheterogenan antar lokasi. Semakin besar nilai indeks gini menandakan semakin besar pula keheterogenan antar lokasi. Perhitungan indeks gini adalah sebagai berikut :

$$G_n = 1 + \frac{1}{576} - \frac{2}{576 \cdot 27.467} 17741.72 = 0.9874$$

Dari perhitungan didapatkan nilai indeks gini sebesar 0.9874. Sehingga dapat disimpulkan bahwa antar lokasi heterogen.

Korelasi Antar Lokasi

Model GSTAR dapat dilakukan ketika terdapat keterikatan antar lokasi dan waktu. Untuk mengetahui keterikatan antar lokasi dapat dilihat dari analisis korelasi. Analisis korelasi dapat dilihat pada Tabel 4.2.

Tabel 4.2 Korelasi Pearson antar lokasi

	Ngadi rejo	Puspo	Wono kitri	Argosar i	Ngada s	Wonok erto
Ngadirejo	1	0.685	0.617	0.606	0.418	0.638
<i>p-value</i>	0.000	0.000	0.000	0.000	0.000	0.000
Puspo	0.685	1	0.645	0.625	0.494	0.628
<i>p-value</i>	0.000	0.000	0.000	0.000	0.000	0.000
Wonokitri	0.617	0.645	1	0.646	0.512	0.692
<i>p-value</i>	0.000	0.000	0.000	0.000	0.000	0.000
Argosari	0.606	0.625	0.646	1	0.653	0.706
<i>p-value</i>	0.000	0.000	0.000	0.000	0.000	0.000
Ngadas	0.418	0.494	0.512	0.653	1	0.561
<i>p-value</i>	0.000	0.000	0.000	0.000	0.000	0.000
Wonokerto	0.638	0.628	0.692	0.706	0.561	1
<i>p-value</i>	0.000	0.000	0.000	0.000	0.000	0.000

Dari Tabel 4.2 didapatkan *p-value* dari semua lokasi bernilai kurang dari taraf nyata (0.05), sehingga dapat disimpulkan curah hujan di enam lokasi di wilayah Tengger mempunyai hubungan yang nyata. Misalnya korelasi curah hujan pada wilayah Ngadirejo dan Puspo adalah 0.685 dengan *p-value* sebesar 0.000, hal ini menunjukkan bahwa hubungan antar dua lokasi tersebut erat dan nyata.

Uji Stasioneritas

Stasioneritas ragam

Pengujian stasioneritas terhadap ragam dilakukan dengan plot *Box-Cox*. Hasil pemeriksaan kestasioneran terhadap ragam adalah sebagai berikut:

Tabel 4.3. Hasil Transformasi Box-cox

Lokasi	λ	Transformasi						Transformasi akhir
		I		II		III		
		Trans	λ	Trans	λ	Trans	λ	
Ngadirejo	0.00	Ln Z_t	0.50	$Z_t^{0.5}$	1.25	$Z_t^{1.25}$	1.00	$(\ln Z_t)^{0.625}$
Puspo	0.00	Ln Z_t	0.50	$Z_t^{0.5}$	1.25	$Z_t^{1.25}$	1.00	$(\ln Z_t)^{0.625}$
Wonokitri	0.25	$Z_t^{0.25}$	0.75	$Z_t^{0.75}$	1.00	-	-	$Z_t^{0.1875}$
Argosari	0.25	$Z_t^{0.25}$	1.25	$Z_t^{1.25}$	1.25	-	-	$Z_t^{0.3125}$
Ngadas	0.00	Ln Z_t	1.00	-	-	-	-	ln Z_t
Wonokerto	0.00	Ln Z_t	0.50	$Z_t^{0.5}$	1.25	$Z_t^{1.25}$	1.00	$(\ln Z_t)^{0.625}$

Berdasarkan Tabel 4.3 nilai λ pada data curah hujan di Wilayah Tengger tidak sama dengan 1. Sehingga dilakukan transformasi seperti pada Tabel 1.3 sampai diperoleh nilai λ sama dengan 1 yang berarti data stasioner terhadap ragam.

Stasioneritas rata - rata

Kestasioneran terhadap rata-rata curah hujan untuk masing-masing lokasi dapat dilihat menggunakan uji *Augmented Dickey Fuller*. Hasil pemeriksaan kestasioneran terhadap rata-rata dapat dilihat pada Tabel 4.4.

Tabel 4.4. Uji Augmented Dickey Fuller

Lags		0	1	2
Ngadirejo	τ	-2.43	-1.48	-1.11
	<i>p-value</i>	0.0148	0.1291	0.2426
Puspo	τ	-2.03	-1.34	-0.96
	<i>p-value</i>	0.0408	0.1687	0.3012
Wonokitri	τ	-1.36	-0.94	-0.76
	<i>p-value</i>	0.1614	0.3086	0.3897
Argosari	τ	-1.87	-1.12	-0.84
	<i>p-value</i>	0.059	0.2395	0.3547
Ngadas	τ	-3.37	-2.29	-1.68
	<i>p-value</i>	0.0008	0.0213	0.0886
Wonokerto	τ	-2.21	-1.48	-1.21
	<i>p-value</i>	0.0264	0.1312	0.2072

Berdasarkan tabel 4.4, *P-value* uji *Augmented Dickey Fuller* dari keenam lokasi yaitu Ngadirejo, Puspo, Wonokitri, Argosari, Ngadas, Wonokerto lebih besar dari taraf nyata. Hal tersebut menunjukkan bahwa data belum stasioner terhadap rata-rata

sehingga perlu dilakukan *differencing* supaya data stasioner terhadap rata-rata. Hasil *differencing* pertama disajikan pada Tabel 4.5.

Tabel 4.5. Uji Augmented Dickey Fuller setelah

Lags		0	1	2
Ngadirejo	τ	-28.73	-19.64	-15.25
	<i>p-value</i>	<.0001	<.0001	<.0001
Puspo	τ	-27.19	-19.97	-14.61
	<i>p-value</i>	<.0001	<.0001	<.0001
Wonokitri	τ	-28.38	-19.14	-16.07
	<i>p-value</i>	<.0001	<.0001	<.0001
Argosari	τ	-29.58	-21.66	-15.53
	<i>p-value</i>	<.0001	<.0001	<.0001
Ngadas	τ	-29.47	-22.27	-17.82
	<i>p-value</i>	<.0001	<.0001	<.0001
Wonokerto	τ	-28	-19.38	-15.51
	<i>p-value</i>	<.0001	<.0001	<.0001

differencing pertama

Dari uji *Augmented Dickey Fuller p-value* telah bernilai kurang dari taraf nyata (0.05), artinya data sudah stasioner terhadap rata-rata.

Identifikasi Model

Identifikasi model digunakan untuk mencari orde *autoregressive* model GSTAR. Orde *autoregressive* ini didapatkan dari identifikasi lag MPACF yang nyata kemudian dari beberapa lag yang nyata tersebut dipilih yang terbaik menggunakan AIC. Lag yang mempunyai nilai AIC terkecil akan digunakan sebagai orde *autoregressive* model GSTAR. Hasil skema MPACF ditunjukkan pada tabel 4.6.

Tabel 4.6 Skema MPACF Data Curah Hujan

Schematic Representation of Partial Cross Correlations												
Variabel/ Lag	1	2	3	4	5	6	7	8	9	10	11	12
Ngadirejo	-.-. .	-.-. .	-.-.+	-.-. .	-.-.+. .
Puspo	-.-. .	-.-.-	-.-. .	..-.
Wonokitri	..-. .	+.-. .	..-. ++.
Argosari	...-.-.-. .	.+.- .+	.+....	++.-.-.+....
Ngadas	.+.-.-.-.+....+
Wonokerto----+.+.--.-.

+ is > 2*std error, - is < -2*std error, . is between

Berdasarkan Tabel 4.6 dapat disampaikan bahwa terdapat lag MPACF yang nyata pada lag 1 sampai lag 12. Dari beberapa lag nyata tersebut kemudian dipilih salah satu dengan melihat nilai AIC terkecil. Hasil AIC untuk lag yang nyata disajikan secara ringkas pada Tabel 4.7:

Tabel 4.7 Nilai AIC untuk Pemilihan Orde Model

Model	AIC
GSTAR (0)	-11.0763
GSTAR (1)	-12.5206
GSTAR (2)	-12.8487
GSTAR (3)	-13.0385
GSTAR (4)	-13.0782
GSTAR (5)	-13.0890
GSTAR (6)	-13.0622
GSTAR (7)	-13.1101
GSTAR (8)	-13.0001
GSTAR (9)	-12.8821

Tabel 4.7 menunjukkan bahwa model GSTAR (7) menghasilkan nilai AIC terkecil sehingga model yang terpilih adalah model GSTAR orde 7. Data curah hujan cenderung memiliki pola musiman. Untuk menentukan orde musiman dari

data curah hujan digunakan dengan analisis spektral.

Plot spektral menunjukkan bahwa periode ke-36 merupakan periode yang lonjakannya paling tinggi daripada periode yang lain. Maka dapat disimpulkan bahwa orde musiman berada pada periode ke-36 atau pada 360 hari, sehingga didapatkan model GSTAR ((1,2,3,4,5,6,7,36(1))).

Penentuan Bobot Lokasi

Bobot lokasi yang digunakan dalam penelitian ini adalah bobot lokasi normalisasi korelasi silang. Bobot lokasi normalisasi korelasi silang dapat menunjukkan semua bentuk korelasi antar lokasi. Pada penelitian untuk enam lokasi nilai $n_i^{(1)}$ atau banyaknya lokasi yang berdekatan dengan lokasi i adalah 6 lokasi sehingga matriks bobot normalisasi korelasi silang sebagai berikut :

$$w_{ij} = \begin{bmatrix} 0 & 0.119 & 0.189 & 0.229 & 0.166 & 0.297 \\ 0.136 & 0 & 0.404 & 0.245 & 0.208 & 0.007 \\ 0.093 & 0.298 & 0 & 0.361 & 0.059 & 0.189 \\ 0.327 & 0.303 & 0.163 & 0 & 0.041 & 0.166 \\ 0.285 & 0.260 & 0.265 & 0.022 & 0 & 0.167 \\ 0.172 & 0.022 & 0.155 & 0.371 & 0.279 & 0 \end{bmatrix}$$

Pembentukan Model GSTAR-Backpropagation Neural Network

Pembentukan arsitektur model GSTAR-*Backpropagation Neural Network* terdiri dari semua variabel pada model GSTAR (1,2,3,4,5,6,7,36,(1)) yang dimasukkan menjadi 96 *neuron input*. Arsitektur model GSTAR-BNN memiliki 6 *neuron* pada *output layer*. *Neuron output* merupakan curah hujan di 6 lokasi yaitu Ngadirejo, Puspo, Wonokitri, Argosari, Ngadas, Wonokerto. Arsitektur yang digunakan hanya memiliki 1 *hidden layer*, untuk menentukan jumlah *neuron* pada *hidden layer* dilakukan uji coba dengan menghitung nilai MSE. Banyaknya *neuron* yang dicoba dimulai dari 90, 95, 100, 105, 110, 115, 120, 125, 130, 135, dan 140 *neuron*. Nilai MSE dapat dilihat pada Tabel 4.8.

Tabel 4.8 Uji Coba Jumlah Neuron dalam Hidden Layer

Jumlah neuron	MSE <i>training</i>	MSE <i>testing</i>
90	0.00275	0.016583
95	0.00349	0.018682
100	0.00231	0.015199
105	0.00278	0.016673
110	0.00193	0.013892
115	0.00251	0.015843
120	0.00147	0.012124
125	0.00255	0.015969
130	0.00267	0.01634
135	0.00275	0.016583
140	0.00177	0.013304

Dari hasil uji coba *neuron* pada *hidden layer* didapatkan nilai MSE terkecil dengan 120 *neuron*. Oleh karena itu model GSTAR-RNN yang terbentuk adalah GSTAR (1,2,3,4,5,6,7,36(1)) BNN (96-120-6). Model yang terbentuk dari proses training adalah sebagai berikut :

$$\hat{Y}_k = w_{oj} + \sum_{j=1}^{120} w_{jk} \left(\frac{1}{1 + e^{-(v_{oi} + \sum_{i=1}^{96} v_{ij} X_i)}} \right)$$

di mana :

X_i = Peubah prediktor ke-i, (324x96)

v_{oj} = Nilai bobot dari bias ke *neuron hidden layer* ke-j, (1x120)

v_{ij} = Nilai bobot dari *neuron input layer* ke-i ke *neuron hidden layer* ke-j, (96x120)

w_{ok} = Nilai bobot dari bias ke *neuron output layer* ke-k, (1x6)

w_{jk} = Nilai bobot dari *neuron hidden layer* ke-j ke *neuron output layer* ke-k, (120x6)

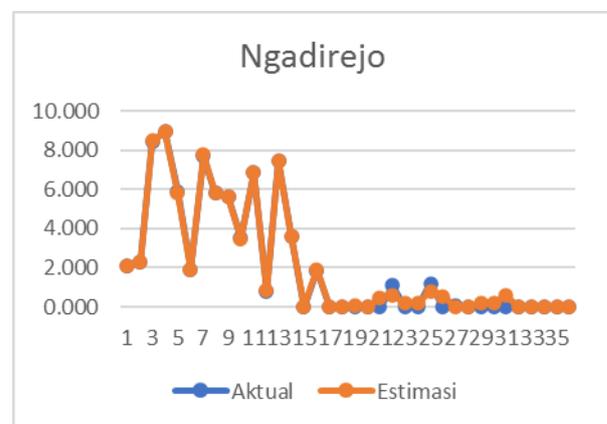
\hat{Y}_k = Peubah respon ke-k, (6x324)

Hasil nilai estimasi di uji validasi untuk mengetahui kehandalannya. Pengujian validitas data training dengan nilai estimasi disajikan pada tabel 4.9.

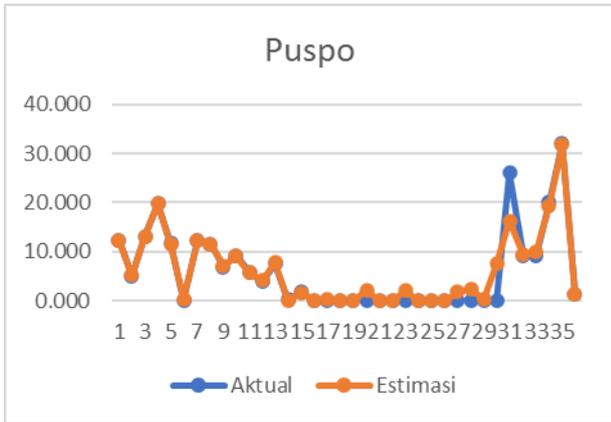
Tabel 4.9 Hasil Pengujian Validitas Pelatihan data training

Pos Hujan	t-hitung	<i>p-value</i>
Ngadirejo	0.02	0.985
Puspo	0.02	0.985
Wonokitri	0.02	0.986
Argosari	0.01	0.996
Ngadas	0.01	0.988
Wonokerto	0.01	0.988

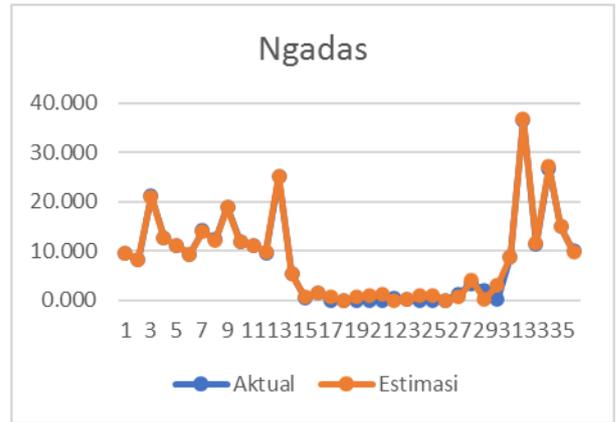
Berdasarkan tabel 4.9 dapat disampaikan bahwa model GSTAR (1,2,3,4,5,6,7,36(1)) *Backpropagation Neural Network* (96-120-6) di keenam wilayah didapatkan *p-value* lebih besar dari taraf nyata (0.05). Dapat dikatakan bahwa tidak terdapat perbedaan pada rata-rata curah hujan *training* dengan rata-rata curah hujan estimasi di enam wilayah tersebut. Model GSTAR (1,2,3,4,5,6,7,36(1)) *Backpropagation Neural Network* (96-120-6) valid untuk meramalkan curah hujan di enam lokasi di wilayah Temgger. Plot hasil prediksi curah hujan pada data *testing* ditunjukkan pada Gambar 4.2 hingga Gambar 4.7 sebagai berikut :



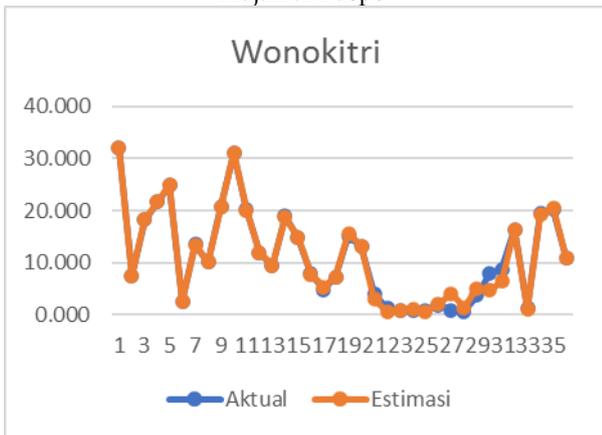
Gambar 4.2. Plot Data dan Nilai Estimasi Curah Hujan di Ngadirejo



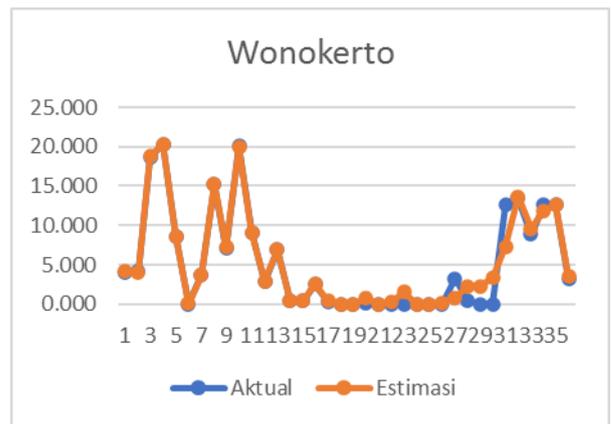
Gambar 4.3. Plot Data dan Nilai Estimasi Curah Hujan di Puspo



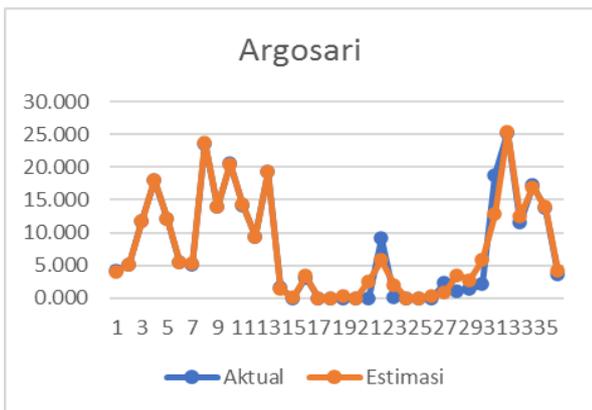
Gambar 4.6. Plot Data dan Nilai Estimasi Curah Hujan di Ngadas



Gambar 4.4. Plot Data dan Nilai Estimasi Curah Hujan di Wonokitri



Gambar 4.7. Plot Data dan Nilai Estimasi Curah Hujan di Wonokerto



Gambar 4.5. Plot Data dan Nilai Estimasi Curah Hujan di Argosari

Berdasarkan gambar 4.2 menunjukkan pola nilai estimasi hampir menyerupai data *testing* keseluruhan. Model *GSTAR-Backpropagation Neural Network* dapat meramalkan nilai data *testing* pada wilayah Ngadirejo dengan akurasi sebesar 75% sedangkan gambar 4.3. menunjukkan pola nilai estimasi hampir menyerupai data *testing*. Model *GSTAR-Backpropagation Neural Network* dapat meramalkan nilai data *testing* pada wilayah Puspo dengan akurasi sebesar 80,5%. Pada gambar 4.4 dan 4.5 menunjukkan bahwa model dapat meramalkan nilai data *testing* pada wilayah

Wonokitri dan Argosari sebesar 91,67%. dan 77,78%. Pada wilayah Ngadas dan Wonokerto ditunjukkan pada gambar 4.6 dan gambar 4.7. Nilai estimasi yang hampir menyerupai data *testing*. Model *GSTAR-Backpropagation Neural Network* dapat meramalkan nilai data *testing* pada wilayah Ngadas memiliki akurasi sebesar 83,33% dan wilayah Wonokerto sebesar 77,78%

Uji Validitas Model

Pengujian validitas model dilakukan dengan uji t. Hasil uji t antara nilai estimasi curah hujan dan data *testing* dirangkum secara ringkas pada tabel 4.10.

Tabel 4.10 Hasil Pengujian Validitas Model

Pos Hujan	t-hitung	p-value
Ngadirejo	-0.06	0.958
Puspo	-0.11	0.916
Wonokitri	0.01	0.995
Argosari	-0.06	0.995
Ngadas	-0.08	0.934
Wonokerto	-0.06	0.953

Berdasarkan tabel 4.10 dapat disampaikan bahwa model GSTAR (1,2,3,4,5,6,7,36(1)) *Backpropagation Neural Network* (96-120-6) di keenam wilayah didapatkan *p-value* lebih besar dari taraf nyata (0.05) sehingga dapat dikatakan bahwa tidak terdapat perbedaan pada rata-rata curah hujan aktual dengan rata-rata curah hujan estimasi di enam lokasi tersebut. Model GSTAR (1,2,3,4,5,6,7,36(1)) *Backpropagation Neural Network* (96-120-6) valid untuk meramalkan curah hujan di enam lokasi di wilayah Tengger.

KESIMPULAN

Kesimpulan dari penelitian ini adalah model yang tepat dalam melakukan peramalan pada data curah hujan pada 6 lokasi Tengger adalah model GSTAR (1,2,3,4,5,6,7,36(1)) *Backpropagation Neural Network* (96-120-6). Hal tersebut dapat dilihat dari hasil pengujian validitas model dengan uji t antara nilai estimasi dan data *testing* memberikan hasil tidak terdapat perbedaan pada rata-rata curah hujan aktual dengan rata-rata curah hujan estimasi di enam lokasi tersebut.

REFERENSI

Ahmad, A. (2017). Mengenal artificial intelligence, machine learning, neural network, dan deep learning. *J. Teknol. Indones.*, no. October, 3.

Fransiska, H., Novianti, P., & Agustina, D. (2019). Permodelan Curah Hujan Bulanan Di Kota Bengkulu Dengan Seasonal Autoregressive Integrated Moving Average (SARIMA).

In Seminar Nasional Official Statistics (Vol. 2019, No. 1, pp. 390-395).

Fransiska, H., Sunandi, E., & Agustina, D. (2020). Peramalan Curah Hujan Provinsi Bengkulu dengan Generalized Space-Time Autoregressive. *MUST: Journal of Mathematics Education, Science and Technology*, 5(2), 130-142.

Iriany, A., Suhariningsih, Ruchjana, B. N., & Setiawan. (2013). Prediction of Precipitation Data at Batu Town Using the GSTAR (1, p) -SUR Model. *Journal of Basic and Applied Scientific Research*, 3(6), 860-865.

Madyatmadja, E. D., Ridho, M. N., Pratama, A. R., Fajri, M., & Novianto, L. (2022). Penerapan Visualisasi Data terhadap Klasifikasi Tindak Kriminal di Indonesia. *Infotech: Journal of Technology Information*, 8(1), 61-68.

Mogea, R. A., Putri, W. I. C. L. H., & Abubakar, H. (2022). Isolasi Bakteri Penghasil Indole Acetic Acid pada Tanaman Hortikultura di Perkebunan Prafi SP 1, Manokwari. *Jurnal Ilmu Pertanian Indonesia*, 27(1), 1-6.

Pamungkas, M. B., & Wibowo, A. (2019). Aplikasi metode arima box-jenkins untuk meramalkan kasus DBD di Provinsi Jawa Timur. *The Indonesian Journal of Public Health*, 13(2), 183.

Pfeifer, P. E., & Deutsch, S. J. (1980). Stationarity and Invertibility Regions for Low Order STARMA Models. *Communications in Statistics-Simulation and Computation*, 9 no. 5, 551-562.

Pramesthi, W. Q., & Saputro, D. R. S. (2023). Estimasi Parameter Generalized Space Time Autoregressive Integrated Moving Average (GSTARIMA) dengan Pendekatan Seemingly Unrelated Regression (SUR). In *PRISMA, Prosiding Seminar Nasional Matematika* (Vol. 6, pp. 714-719).

Rizal, A. A., & Hartati, S. (2017). Prediksi kunjungan wisatawan dengan recurrent neural network extended kalman filter. vol. X, (1), 7-18.

Ruchjana, B. N. (2002). A Generalized Space Time Autoregressive Model and its Application to Oil Production Data. ITB.

- Saptono, L., & Harsoyo, Y. (2022). *Statistika Deskriptif Untuk Pendidikan Ekonomi*. Sanata Dharma University Press.
- Sari, V., & Maulidany, D. A. (2020). Prediksi Kecepatan Angin Dalam Mendeteksi Gelombang Air Laut Terhadap Skala Beaufort Dengan Metode Hybrid Arima-Ann (Studi Kasus: Kabupaten Lombok Barat 2019). *Jurnal Statistika Universitas Muhammadiyah Semarang*, 8(1).
- Setiawan, Suhartono, & Prastuti, M. (2016). S-GSTAR-SUR model for seasonal spatio temporal data forecasting. *Malaysian Journal of Mathematical Sciences*, 10, 53-65.
- Wardah, S., & Iskandar, I. (2017). Analisis Peramalan Penjualan Produk Keripik Pisang Kemasan Bungkus (Studi Kasus: Home Industry Arwana Food Tembilahan). *J@ ti undip: jurnal teknik industri*, 11(3), 135-142.
- Wutsqa, D. U., & Suhartono. 2010. Peramalan Deret Waktu Multivariat Seasonal pada Data Pariwisata dengan Model VAR-GSTAR. *Jurnal Ilmu Dasar*, 11(1): 101-109