



Peramalan Jumlah Kunjungan Wisatawan Menggunakan Model *Generalized Space Time Autoregressive-Seemingly Unrelated Regression-Neural Network*

Raihan Ayita Putri*, Entit Puspita, dan Fitriani Agustina

Jurusan Matematika, Fakultas Pendidikan Matematika dan Ilmu Pengetahuan Alam
Universitas Pendidikan Indonesia Bandung, Indonesia

*Correspondence: E-mail: raihanputri2609@upi.edu

ABSTRAK

Model *Generalized Space Time Autoregressive* (GSTAR) adalah suatu model *space time* yang stasioner. Salah satu data yang memiliki fenomena *space time* adalah jumlah kunjungan wisatawan, yang terkadang sulit untuk diprediksi karena memiliki pola dan karakteristik yang sulit untuk diidentifikasi. Model yang mempertimbangkan unsur non linier adalah *Neural Network* (NN). Pendugaan parameter model GSTAR yang digunakan adalah model *Seemingly Unrelated Regression* (SUR). Data jumlah kunjungan wisatawan di Kabupaten Magelang merupakan salah satu data runtun waktu yang memiliki keterkaitan antar lokasi, memiliki residual yang berkorelasi, dan juga pola data yang nonlinier sehingga dapat dimodelkan dengan model GSTAR-SUR-NN. Pada penelitian ini dilakukan beberapa tahapan untuk mengetahui model terbaik dan hasil peramalan jumlah kunjungan wisatawan pada empat lokasi di Kabupaten Magelang, yaitu Telaga Bleder, Candi Borobudur, Bukit Rhema, dan Candi Mendut dengan model GSTAR-SUR-NN. Model yang dipilih untuk meramalkan jumlah kunjungan wisatawan di empat tempat lokasi wisata di Kabupaten Magelang untuk 12 bulan mendatang adalah GSTAR(1,1)-SUR-NN(4,7,4) karena model ini menghasilkan hasil ramalan lebih baik daripada model GSTAR(1,1)-SUR.

© 2023 Kantor Jurnal dan Publikasi UPI

ABSTRACT

The *Generalized Space Time Autoregressive* (GSTAR) model is a stationary *space time* model. One of the data that has a *spacetime* phenomenon is the number of tourist visits that sometimes difficult to predict because it has patterns and characteristics that are difficult to identify. The model that considers non-linear elements is a neural network. The parameter estimation of the GSTAR model used is the *Seemingly Unrelated Regression* (SUR) model. Data on the number of tourist visits in Magelang Regency is one of the time series data that has links between locations, has correlated residuals, and also nonlinear data patterns so that it can be modeled with the GSTAR-SUR-NN model. In this research, steps were taken to find out the best model and the results of forecasting the number of tourist visits at four locations in Magelang Regency, namely Telaga Bleder, Borobudur Temple, Bukit Rhema, and Mendut Temple with the GSTAR-SUR-NN model. The model chosen to predict the number of tourist visits at four tourist sites in Magelang Regency for the next 12 months is GSTAR(1,1)-SUR-NN(4,7,4) because this model produces better forecast results than the GSTAR(1,1)-SUR.

© 2023 Kantor Jurnal dan Publikasi UPI

INFORMASI ARTIKEL

Sejarah Artikel:

Diterima 5 Februari 2023

Direvisi 27 Februari 2023

Disetujui 21 Maret 2023

Tersedia online 1 Mei 2023

Dipublikasikan 1 Juni 2023

Kata Kunci:

GSTAR-SUR,
Neural Network,
Wisatawan.

Keywords:

GSTAR-SUR,
Neural Network,
Tourist visit.

1. PENDAHULUAN

Model ruang-waktu (*space time*) adalah model yang menggabungkan elemen dependensi waktu dan lokasi untuk data runtun waktu (Kurniawati, et. al., 2017). Salah satu bagian dari model *space time* adalah model *Space Time Autoregressive* (STAR). Model STAR adalah model yang melibatkan lokasi dan waktu dengan asumsi bahwa lokasi memiliki karakteristik yang sama. Model STAR pertama kali dikemukakan oleh Cliff dan Ord pada tahun 1973. Akan tetapi menurut (Handayani, et.al., 2018) model STAR memiliki kelemahan yaitu mengasumsikan parameter autoregresif berlaku sama untuk semua lokasi, sehingga model ini hanya berlaku untuk lokasi dengan karakteristik yang homogen.

Berdasarkan studi yang dilakukan sebelumnya, terdapat model *space time* lain yang mengasumsikan lokasi dengan karakteristik berbeda, yaitu model *Generalized Space Time Autoregressive* (GSTAR). Model GSTAR lebih fleksibel daripada model STAR karena asumsi parameter autoregresif yang dimiliki oleh model GSTAR bervariasi dari satu lokasi ke lokasi lain dan sesuai untuk diterapkan pada lokasi dengan karakteristik yang beragam (heterogen). Namun ada kemungkinan bahwa antara satu lokasi dengan lokasi lain dengan karakteristik yang berbeda memiliki korelasi di mana model GSTAR tidak dapat mendeteksi korelasi antar lokasi tersebut. Salah satu model *space time* yang dapat mengatasi korelasi yang terjadi antar lokasi adalah model *Generalized Space Time Autoregressive- Seemingly Unrelated Regression* (GSTAR-SUR).

Meskipun model GSTAR-SUR dapat mendeteksi adanya sesatan yang berkorelasi antar lokasi, model ini tetap memiliki kelemahan, yaitu hanya dapat mengenali model linier. Salah satu model pengenalan nonlinier yang baru dikembangkan adalah Jaringan Syaraf Tiruan atau *Artificial Neural Network*. Diani, et. al. (2013) menggunakan jaringan syaraf tiruan berdasarkan masukan GSTAR, membandingkan model VAR-NN dengan model GSTAR-NN untuk memprediksi curah hujan di Kabupaten Malang dengan akurasi ramalan terbaik dimiliki oleh model VAR-NN. Zhang (2003) menerapkan model hibrida yang menggabungkan ARIMA dan jaringan syaraf tiruan dengan menerapkan jaringan syaraf tiruan ke residual ARIMA.

Dalam penelitian ini, model GSTAR-SUR-NN diterapkan untuk memprediksi jumlah kunjungan wisatawan. Model yang diharapkan adalah model yang menggambarkan hubungan waktu-lokasi dari data jumlah kunjungan wisatawan berdasarkan penentuan bobot lokasi yang memberikan nilai kesalahan prediksi terendah.

2. METODE

Data yang digunakan dalam penelitian ini adalah data jumlah kunjungan wisatawan di empat lokasi wisata di Kabupaten Magelang, yaitu Telaga Bledar, Candi Borobudur, Bukit Rhema, dan Candi Mendut. Periode data jumlah kunjungan wisatawan mulai tahun 2017 sampai 2022. Data curah hujan ini merupakan data per bulan. Adapun konsep dalam penelitian ini adalah membentuk model GSTAR-SUR dan model GSTAR-SUR-NN, kemudian membandingkan hasil ramalan dari kedua model tersebut berdasarkan nilai RMSE.

2.1 Analisis Runtun Waktu

Analisis runtun waktu pertama kali diperkenalkan dan dikembangkan oleh Box dan Jenkins pada tahun 1970. Analisis runtun waktu adalah analisis terhadap sekumpulan data pada periode waktu tertentu di masa lalu dan membantu untuk memahami atau memprediksi kondisi masa depan. Menurut (Efendi, et. al., 2019) Berdasarkan nilai observasinya, runtun waktu dapat dibagi menjadi dua jenis, yaitu runtun waktu deterministik dan runtun waktu stokastik. Runtun waktu deterministik adalah runtun waktu di mana situasi masa depan dapat

diprediksi dengan pasti dan tidak perlu diselidiki. Runtun waktu stokastik adalah runtun waktu dimana nilai observasi yang lampau hanya dapat menunjukkan struktur probabilistik nilai observasi yang akan datang (Rafulta, 2016).

2.2 Model GSTAR

Model GSTAR adalah pengembangan dari model STAR ($\rho_{\lambda_1, \lambda_2, \dots, \lambda_k}$). Perbedaan utama antara model STAR dan model GSTAR ini terletak pada parameter *autoregressive* (ϕ_{kl}), pada model STAR ($\rho_{\lambda_1, \lambda_2, \dots, \lambda_k}$) nilai (ϕ_{kl}) bernilai sama untuk setiap lokasi sehingga menyebabkan model lebih sesuai diaplikasikan pada lokasi yang memiliki karakteristik. Untuk melakukan pemodelan *space time* pada lokasi yang memiliki karakteristik heterogen digunakan model GSTAR dengan nilai (ϕ_{kl}) yang berbeda pada setiap lokasi sehingga diperoleh model GSTAR yang memiliki matriks diagonal $\phi_{kl}^{(i)}$ dengan nilai berbeda pada setiap lokasi-*i*, Model *Generalized Space Time Autoregressive* (GSTAR) dengan orde *autoregressive* p dan orde spasial $\lambda_1, \lambda_2, \dots, \lambda_k$ dapat ditulis sebagai berikut (Wutsqa, 2010):

$$\mathbf{Z}_t = \sum_{k=1}^p \left(\phi_{k0} + \sum_{l=1}^{\lambda_k} \phi_{kl} \mathbf{W}^{(l)} \right) \mathbf{Z}(t-k) + \boldsymbol{\varepsilon}_t$$

dengan

\mathbf{Z}_t : Vektor acak berukuran ($n \times 1$) pada waktu t

p : orde *autoregressive*

λ_k : orde spasial ke- k

$\mathbf{W}^{(l)}$: Matriks pembobot berukuran pada lag spasial l dengan $l = 0, 1, \dots, n$.

ϕ_{kl} : Diagonal matriks parameter dari waktu lag ke- k dan lag spasial l

$\boldsymbol{\varepsilon}_t$: Vektor sisaan berukuran ($n \times 1$).

2.3 Model SUR

Model SUR merupakan model yang terdiri dari beberapa persamaan yang saling berkorelasi. Secara umum model SUR dapat dinyatakan sebagai himpunan Gbuah persamaan yang berhubungan karena galat antar persamaan yang berbeda saling berkorelasi. Menurut Zellner (1962), model SUR dapat ditulis ke dalam bentuk sebagai berikut:

$$Y_{1t} = \beta_1 + \beta_{11}X_{11,t} + \dots + \beta_{1K_1}X_{1K_1,t} + e_{1t}$$

$$Y_{2t} = \beta_2 + \beta_{21}X_{21,t} + \dots + \beta_{2K_2}X_{2K_2,t} + e_{2t}$$

...

$$Y_{Gt} = \beta_G + \beta_{G1}X_{G1,t} + \dots + \beta_{GK_G}X_{GK_G,t} + e_{Gt}$$

untuk $t = 1, 2, 3, \dots, n$. Persamaan tersebut apabila disajikan dalam notasi matriks diperoleh sebagai berikut:

$$\mathbf{Y}^* = \mathbf{X}^* \boldsymbol{\beta}^* + \mathbf{e}^*$$

$$Y^* = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_G \end{bmatrix}, X^* = \begin{bmatrix} x_1 & 0 & \dots & 0 \\ 0 & x_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & x_G \end{bmatrix}, \beta^* = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_G \end{bmatrix}, \text{ dan } e^* = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_G \end{bmatrix}$$

dengan Y^* adalah vektor kolom nilai variabel terikat yang berukuran $n \times 1$, X^* adalah matriks nilai variabel bebas yang berukuran $K_1 \times 1$, β^* adalah vektor parameter model SUR yang berukuran $K_1 \times 1$, K_i adalah dimensi vektor sedangkan e^* adalah vektor kolom galat yang berukuran $n \times 1$ berdistribusi normal multivariat.

2.4 Jaringan Syaraf Tiruan *Backpropagation*

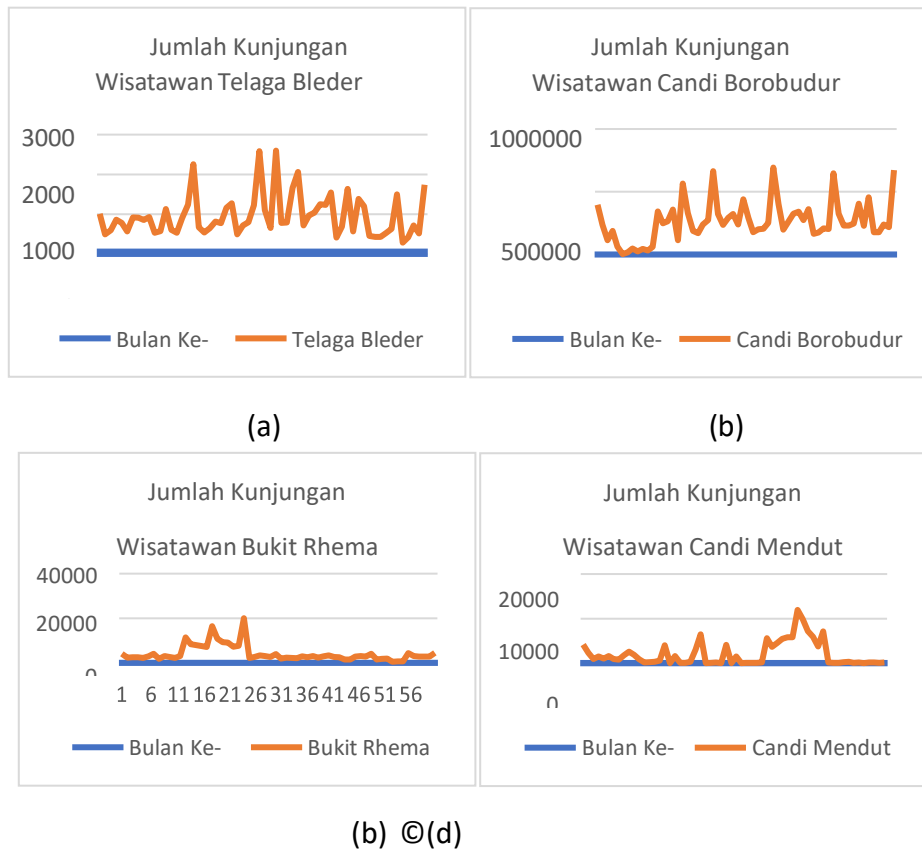
Sebuah Jaringan Syaraf Tiruan (JST) adalah sebuah paradigma pengolahan informasi yang terinspirasi dari sistem kerja syaraf biologis, seperti kinerja otak, yang memproses suatu informasi (Cynthia & Ismanto, 2017; Rahmadani, et. al., 2021). Diungkapkan oleh Kusumadewi, dalam bukunya yang berjudul "Pemrograman Dasar Matlab" pada tahun 2004, *backpropagation* adalah salah satu algoritma *multilayer perceptron*, yang pertama kali dirumuskan oleh Werbos dan digeneralisasikan oleh Rumelhart dan McClelland untuk digunakan dalam JST. Seperti model JST lainnya, jaringan pelatihan *backpropagation* melibatkan kemampuan jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan untuk mengenali pola yang digunakan selama pelatihan serta kemampuan untuk memberikan respon yang benar terhadap pola masukan yang serupa dengan pola yang dipakai selama pelatihan (Jumarwanto, et. al., 2009). Tahapan metode *Backpropagation* pada JST terdiri dari 2 tahap yaitu:

- i) Langkah pelatihan. Langkah ini dimulai dengan menginisialisasi bobot, menentukan konfigurasi JST yaitu maksimum *epoch*, kesalahan target, laju pembelajaran/*learning rate*, dan beralih ke fase alur maju (*feedforward*). Tahap *backpropagation* berlanjut dan RMSE (*Root Mean Squared Error*) dihitung. Jika *error* yang diperoleh lebih besar dari *target error* yang dapat diterima, proses pelatihan kembali ke langkah inisialisasi bobot dan berulang hingga nilai *error* lebih kecil dari *target error* yang dapat diterima sehingga ketika nilai yang diinginkan diperoleh, bobot disimpan untuk dimasukkan pada langkah selanjutnya, yaitu pengujian.
- ii) Langkah pengujian ini menggunakan bobot yang diperoleh pada langkah pelatihan untuk pengujian. Sistem yang telah dibuat akan menggunakan data jumlah kunjungan wisatawan untuk diuji. Tahap pengujian ini hanya menggunakan tahap *feedforward*.

3. HASIL DAN PEMBAHASAN

3.1 Deskripsi Data

Gambaran secara umum data yang akan dianalisis terdapat pada Gambar 1. Berdasarkan Gambar 1, data jumlah kunjungan wisatawan di Telaga Bleder, Candi Borobudur, Bukit Rhema, dan Candi Mendut memiliki pola yang belum stasioner terhadap varians sehingga perlu dilakukan transformasi Box-Cox. Data dikatakan stasioner dalam varians jika nilai lambda (λ) sama dengan 1.



Gambar 1. Plot Data setiap Lokasi

Kemudian setelah data stasioner dalam varians, dilakukan uji *Augmented Dickey-Fuller* (ADF). Hasil uji ADF pada Tabel 1 menunjukkan bahwa data yang sudah stasioner dalam varians juga sudah stasioner dalam rata-rata, sehingga tidak perlu dilakukan *differencing*.

Tabel 1. Hasil Uji ADF

Lokasi	Probabilitas
Telaga Bleder	0,0000
Candi Borobudur	0,0001
Bukit Rhema	0,0016
Candi Mendut	0,0150

3.2 Model GSTAR

Orde spasial yang digunakan dalam penelitian ini adalah orde 1, sedangkan orde *autoregressive* ditentukan berdasarkan nilai *Aike Information Criterion* (AIC) terkecil. Hasil nilai AIC terdapat pada Tabel 2.

Tabel 2. Hasil Nilai AIC

Lag	AIC
0	12,75151
1	12,71151*
2	12,73322
3	12,72539
4	12,76019

Berdasarkan Tabel 2, nilai lag terkecil (*) berdasarkan AIC adalah lag 1 sehingga model GSTAR yang dipilih adalah GSTAR (1,1). Tahapan selanjutnya adalah estimasi parameter dengan metode OLS. Tabel 3 menampilkan hasil estimasi menggunakan metode OLS.

Pada penelitian ini, parameter yang tidak signifikan pada taraf signifikansi 0,05 tidak akan dimasukkan ke dalam model, sehingga berdasarkan Tabel 3, model GSTAR(1,1) untuk berbagai lokasi adalah sebagai berikut:

i. Telaga Bleder

$$\hat{Z}_{TB} = 0,002355_{CB}(t - 1) + 0,00157_{BR}(t - 1) + 0,00157_{CM}(t - 1)$$

ii. Candi Borobudur

$$\hat{Z}_{CB} = 0,404_{CB}(t - 1)$$

iii. Bukit Rhema

$$\hat{Z}_{BR} = 0,01_{TB}(t - 1) + 0,198891_{CB}(t - 1) + 0,504_{BR}(t - 1)$$

iv. Candi Mendut

$$\hat{Z}_{CM} = 0,449_{CM}(t - 1)$$

Tabel 3. Hasil Estimasi Parameter dengan Metode OLS

Parameter	Nilai Estimasi	Probabilitas	Kesimpulan
ϕ_{10}^1	0,094	0,6273	Tidak Signifikan
ϕ_{10}^2	0,404	0,0001	Signifikan
ϕ_{10}^3	0,472	0,0031	Signifikan
ϕ_{10}^4	0,449	0,0077	Signifikan
ϕ_{11}^1	0,785	0,0169	Signifikan
ϕ_{11}^2	0,359	0,5132	Tidak Signifikan
ϕ_{11}^3	0,539	0,0413	Signifikan
ϕ_{11}^4	0,239	0,4932	Tidak Signifikan

3.3 Model GSTAR-SUR

Estimasi parameter model GSTAR-SUR dilakukan menggunakan metode *Generalized Least Square* (GLS). Tabel 4 adalah hasil estimasi parameter menggunakan metode GLS.

Tabel 4. Hasil Estimasi Parameter dengan Metode GLS

Parameter	Nilai Estimasi	Probabilitas	Kesimpulan
ϕ_{10}^1	0,116	0,2125	Tidak Signifikan
ϕ_{10}^2	0,565	0,0000	Signifikan
ϕ_{10}^3	0,674	0,0000	Signifikan
ϕ_{10}^4	0,437	0,0000	Signifikan
ϕ_{11}^1	0,282	0,0025	Signifikan
ϕ_{11}^2	0,052	0,5749	Tidak Signifikan
ϕ_{11}^3	0,531	0,0001	Signifikan
ϕ_{11}^4	0,663	0,4379	Tidak Signifikan

Berdasarkan Tabel 4, model GSTAR(1,1)-SUR yang terbentuk untuk berbagai lokasi adalah sebagai berikut:

i. Telaga Bleder

$$\hat{Z}_{TB} = 0,001846_{CB}(t-1) + 0,00564_{BR}(t-1) + 0,00564_{CM}(t-1)$$

ii. Candi Borobudur

$$\hat{Z}_{CB} = 0,565_{CB}(t-1)$$

iii. Bukit Rhema

$$\hat{Z}_{BR} = 0,88062_{TB}(t-1) + 0,00195_{CB}(t-1) + 0,497016_{BR}(t-1)$$

iv. Candi Mendut

$$\hat{Z}_{CM} = 0,437_{CM}(t-1)$$

3.4 Model GSTAR-SUR-NN

Residual model GSTAR(1,1)-SUR akan dilakukan pemodelan neural network sehingga persamaan matematis model GSTAR-SUR-NN adalah sebagai berikut:


$$Z_t = Z_{t,GSTAR} + Z_{t,NN}$$

Pemodelan *Neural Network* untuk analisis data jumlah kunjungan wisatawan di empat lokasi di Kabupaten Magelang menggunakan 4 input berdasarkan residual yang didapat dari model GSTAR(1,1)-SUR. Variabel-variabel *input* tersebut adalah $a_{TB,t-1}$, $a_{CB,t-1}$, $a_{BR,t-1}$, dan $a_{CM,t-1}$. Adapun variabel *output layer* sejumlah variabel yang digunakan dalam pemodelan GSTAR(1,1)-SUR, yaitu sebanyak 4 variabel. Adapun *hidden layer* yang digunakan sebanyak 1 dengan jumlah neuron dibatasi 1 sampai 10 neuron. Pemilihan arsitektur terbaik dilakukan dengan melihat nilai RMSE terkecil dari hasil peramalan. Nilai RMSE pada 10 Neuron dalam *Hidden Layer* disajikan pada Tabel 5.

Tabel 5. Nilai RMSE pada 10 Neuron dalam *Hidden Layer*

Jumlah Neuron	Nilai RMSE	Jumlah Neuron	Nilai RMSE
1	0,0726	6	0,0678
2	0,0713	7	0,0630
3	0,0692	8	0,0753
4	0,0651	9	0,0686
5	0,0644	10	0,0800

Berdasarkan Tabel 5, nilai RMSE terkecil terjadi ketika jumlah neuron dalam *hidden layer* sebanyak 7. Sehingga dapat disimpulkan bahwa arsitektur terbaik dalam pemodelan *neural network* adalah NN(4,7,4). Adapun arsitektur terbaik *neural network* residual model GSTAR(1,1)-SUR ditunjukkan pada Gambar 2.

Gambar 2. Arsitektur Terbaik *Neural Network* Residual Model GSTAR(1,1)-SUR

Adapun persamaan matematis dari model GSTAR(1,1)-SUR-NN(4,7,4) pada masing-masing lokasi adalah sebagai berikut:

- i. Telaga Bleder

$$\hat{Z}_{TB} = Z_{TB,GSTAR-SUR} + Z_{TB,NN}$$

$$\hat{z}_{TB} = 0,001846_{CB}(t-1) + 0,00564_{BR}(t-1) + 0,00564_{CM}(t-1) + 3,1560 - 0,0815f(h_1) - 6,1211f(h_2) + 1,4760f(h_3) + 1,5533f(h_4) - 5,7167f(h_5) - 0,1160f(h_6) + 0,2086f(h_7)$$

ii. Candi Borobudur

$$\hat{z}_{CB} = Z_{CB,GSTAR-SUR} + Z_{CB,NN}$$

$$\hat{z}_{CB} = 0,565_{CB}(t-1) - 4,3637 + 6,8073f(h_1) - 0,1474f(h_2) - 2,5670f(h_3) + 7,4053f(h_4) - 0,4701f(h_5) - 1,6673f(h_6) - 3,2301f(h_7)$$

iii. Bukit Rhema

$$\hat{z}_{BR} = Z_{BR,GSTAR-SUR} + Z_{BR,NN}$$

$$\hat{z}_{BR} = 0,88062_{TB}(t-1) + 0,00195_{CB}(t-1) + 0,497016_{BR}(t-1) + 0,3741 - 2,3189f(h_1) - 3,9161f(h_2) + 7,7304f(h_3) - 0,5768f(h_4) - 3,4361f(h_5) + 2,0420f(h_6) - 13,8072f(h_7)$$

iv. Candi Mendut

$$\hat{z}_{CM} = Z_{CM,GSTAR-SUR} + Z_{CM,NN}$$

$$\hat{z}_{CM} = 0,437_{CM}(t-1) - 1,2464 - 0,1024f(h_1) - 0,4235f(h_2) + 0,7216f(h_3) + 8,5961f(h_4) - 0,3819f(h_5) - 6,0919f(h_6) + 0,3142f(h_7)$$

Adapun $f(h_i)$ adalah fungsi aktivasi sigmoid biner pada *hidden unit* yang didefinisikan sebagai berikut:

$$f(h_i) = \frac{1}{1 + e^{-(h_i)}}, i = 1, 2, \dots, 7$$

dengan

$$h_1 = 2,4245 + 0,3995a_{TB,t-1} + 2,0006a_{CB,t-1} - 0,4106a_{BR,t-1} - 0,8722a_{CM,t-1}$$

$$h_2 = -3,3777 - 2,2610a_{TB,t-1} + 0,2698a_{CB,t-1} - 0,0718a_{BR,t-1} + 0,1129a_{CM,t-1}$$

$$h_3 = 3,0729 - 0,1464a_{TB,t-1} - 1,1196a_{CB,t-1} + 0,6493a_{BR,t-1} + 1,0215a_{CM,t-1}$$

$$h_4 = -2,4841 - 0,1148a_{TB,t-1} + 0,0534a_{CB,t-1} + 0,0356a_{BR,t-1} + 0,09700a_{CM,t-1}$$


$$h_5 = 2,9075 - 1,5174a_{TB,t-1} + 0,0900a_{CB,t-1} + 0,0633a_{BR,t-1} + 0,5287a_{CM,t-1}$$

$$h_6 = -3,8413 + 0,1997a_{TB,t-1} - 0,3594a_{CB,t-1} - 0,0002a_{BR,t-1} - 2,1466a_{CM,t-1}$$

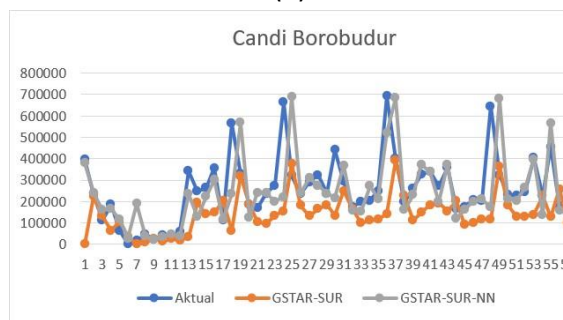
$$h_7 = -0,8680 + 0,2693a_{TB,t-1} - 0,3530a_{CB,t-1} - 0,5915a_{BR,t-1} + 0,1332a_{CM,t-1}$$

3.5 Perbandingan Model GSTAR-SUR dan GSTAR-SUR-NN


Perbandingan model GSTAR-SUR dan GSTAR-SUR-NN dapat dilihat dari plot hasil ramalan. Perbandingan berdasarkan grafik masih bersifat subjektif sehingga kriteria lain yang digunakan adalah dengan menghitung nilai RMSE. Adapun plot hasil ramalan menggunakan model GSTAR-SUR dan GSTAR-SUR-NN terdapat pada Gambar 3.




(a)



(b)



(c)



(d)

Gambar 3. (a) Plot Hasil Ramalan Telaga Bledher, (b) Plot Hasil Ramalan Candi Borobudur, (c) Plot Hasil Ramalan Bukit Rhema, dan (d) Plot Hasil Ramalan Candi Mendut

Berdasarkan Gambar 3, hasil ramalan menggunakan GSTAR(1,1)-SUR dan GSTAR(1,1)-SUR-NN(4,7,4) memiliki pola yang hampir sama dengan data aktual. Gambar 3 masih belum dapat ditentukan model yang lebih baik. Oleh karena itu, pada Tabel 6 ditampilkan nilai RMSE pada masing-masing model.

Tabel 6. Nilai RMSE setiap Model

Model	Nilai RMSE
GSTAR(1,1)-SUR	2,6927
GSTAR(1,1)-SUR-NN(4,7,4)	0,0630

Model yang menghasilkan nilai RMSE terkecil adalah model GSTAR(1,1)-SUR-NN(4,7,4), yaitu sebesar 0,0630. Dapat disimpulkan bahwa model GSTAR(1,1)-SUR-NN(4,7,4) lebih baik dari model GSTAR(1,1)-SUR dalam meramalkan jumlah kunjungan wisatawan di Telaga Bleder, Candi Borobudur, Bukit Rhema, dan Candi Mendut

4. KESIMPULAN

Model GSTAR-SUR-NN terbaik yang digunakan pada peramalan runtunwaktu dengan studi kasus jumlah kunjungan wisatawan di Kabupaten Magelang adalah GSTAR(1,1)-SUR-NN(4,7,4) dengan nilai RMSE sebesar 0,0630. Adapaunsaran untuk penelitian selanjutnya adalah dapat menggunakan model lain dalam meramalkan jumlah kunjungan wisatawan, menambahkan *hidden layer*, atau mengganti input pada model *Neural Network*.

5. DAFTAR PUSTAKA

- Cynthia, E. P., & Ismanto, E. (2017). Jaringan syaraf tiruan algoritma backpropagation dalam memprediksi ketersediaan komoditi pangan provinsi Riau. *Rabit: Jurnal Teknologi dan Sistem Informasi Univrab*, 2(2), 83-98.
- Diani, K. K. N., Setiawan, S., & Suhartono, S. (2013). Pemodelan VAR-NN dan GSTAR-NN untuk peramalan curah hujan di Kabupaten Malang. *Jurnal Sains dan Seni ITS*, 2(1), D19-D24.
- Handayani, R., Wahyuningsih, S., & Yuniarti, D. (2019). Pemodelan Generalized Space Time Autoregressive (GSTAR) pada data inflasi di Kota Samarinda dan Kota Balikpapan. *Eksponensial*, 9(2), 153-162.
- Jumarwanto, A., Hartanto, R., & Prastiyanto, D. (2009). Aplikasi jaringan saraf tiruan backpropagation untuk memprediksi penyakit THT di Rumah Sakit Mardi Rahayu Kudus. *Jurnal Teknik Elektro*, 1(1), 11-21.
- Kurniawati, E., Debatara, N., & Kusnandar, D. (2017). Model space-time dan penerapannya pada produksi kelapa sawit di PT. Perkebunan Nusantara XIII. *Bimaster: Buletin Ilmiah Matematika, Statistika dan Terapannya*, 6(3), 183 – 192.
- Rafulta, E. (2016). Peramalan runtun waktu musiman dengan menggunakan metode wavelet. *Eksakta*, 1, 90-97.
- Rahmadani, F., Pardede, A. M., & Nurhayati, N. (2021). Jaringan syaraf tiruan prediksi jumlah pengiriman barang menggunakan metode backpropagation (Studi kasus: Kantor Pos Binjai). *Jurnal Teknik Informatika Kaputama*, 5(1), 100-106.

- Wutsqa, D. U. (2010). Seasonal multivariat time series forecasting on tourism data by using var-gstar model. *Jurnal Ilmu Dasar*, 11(1), 101-109.
- Zellner, A. (1962). An efficient method of estimating seemingly unrelated regressions and tests for aggregation bias. *Journal of the American Statistical Association*, 57(298), 348-368.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.