

**PEMODELAN *HYBRID* GSTAR–ANN PADA DATA KELEMBABAN  
UDARA DI TIGA LOKASI STASIUN PENGAMATAN  
PROVINSI BANTEN**

**(Skripsi)**

**Oleh**

**NUR AZZURA ASYIFA**

**NPM 2017031037**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2024**

## ABSTRAK

### PEMODELAN *HYBRID* GSTAR–ANN PADA DATA KELEMBABAN UDARA DI TIGA LOKASI STASIUN PENGAMATAN PROVINSI BANTEN

Oleh

NUR AZZURA ASYIFA

Model GSTAR merupakan model yang lebih fleksibel dibandingkan model STAR karena dapat memiliki parameter *autoregressive* berbeda untuk setiap lokasi atau bersifat heterogen. Model GSTAR tentu memiliki keterbatasan, hal ini dapat diatasi dengan menerapkan model *hybrid*. Salah satu model yang dapat digunakan ialah model ANN. Keuntungan model ANN memiliki kemampuan pemodelan nonlinear yang fleksibel. Tujuan dari penelitian ini adalah menerapkan model *hybrid* GSTAR-ANN pada data kelembaban udara di tiga lokasi stasiun pengamatan Provinsi Banten. Data yang digunakan ialah data kelembaban udara di Stasiun Klimatologi Tangerang Selatan, Stasiun Meteorologi Serang dan Stasiun Geofisika Tangerang dengan menggunakan dua bobot lokasi yaitu bobot invers jarak dan bobot normalisasi korelasi silang serta estimasi parameter menggunakan metode *Ordinary Least Square* (OLS). Pemodelan ANN pada penelitian ini menggunakan tiga skema pembagian data *training* dan data *testing* yaitu 60:40, 70:30, dan 80:20. Dari hasil analisis diperoleh model terbaik yaitu model GSTAR ( $1_1$ ) dengan bobot normalisasi korelasi silang yang selanjutnya di kombinasikan dengan model ANN mendapatkan skema yang terbaik yaitu skema 70% *training* 30% *testing* yang mampu menghasilkan nilai MSE sebesar 9.93 dan MAPE 0.031.

Kata kunci: GSTAR, ANN, *hybrid* GSTAR-ANN, Kelembaban Udara, Peramalan

## **ABSTRACT**

### **GSTAR-ANN HYBRID MODELING OF AIR HUMIDITY DATA AT THREE OBSERVATION STATION LOCATIONS IN BANTEN PROVINCE**

**By**

**NUR AZZURA ASYIFA**

The GSTAR model is a more flexible model than the STAR model because it can have different parameters for each location or heterogeneous. The GSTAR model certainly has limitations, this can be overcome by applying a hybrid model. One of the models that can be used is the ANN model. The ANN model has the advantage of flexible nonlinear modeling capabilities. The purpose of this research is to apply the GSTAR-ANN model into air humidity data in three stations in Banten Province. The data used are air humidity data from the South Tangerang Climatology Station, Serang Meteorological Station and Tangerang Geophysical Station using two location weights, namely the inverse distance weight and cross-correlation normalization weight and parameter estimation using the Ordinary Least Square (OLS) method. ANN modeling in this study uses three splitting schemes of dividing training data and testing data, namely 60:40, 70:30, and 80:20. Best on the result of analysis, the best model is the GSTAR (1<sub>1</sub>) model with cross-correlation weights which is combined with the ANN model to get the best scheme, namely the 70% training 30% testing scheme which is able to produce an MSE value of 9.93 and MAPE 0.031.

**Keywords:** GSTAR, ANN, Hybrid GSTAR-ANN, Air Humidity, Forecasting

**PEMODELAN *HYBRID* GSTAR–ANN PADA DATA KELEMBABAN  
UDARA DI TIGA LOKASI STASIUN PENGAMATAN  
PROVINSI BANTEN**

**Oleh**

**NUR AZZURA ASYIFA**

**Skripsi**

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar  
SARJANA MATEMATIKA**

**Pada**

**Jurusan Matematika  
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2024**

Judul Skripsi : **PEMODELAN *HYBRID* GSTAR-ANN  
PADA DATA KELEMBABAN UDARA  
DI TIGA LOKASI STASIUN  
PENGAMATAN PROVINSI BANTEN**

Nama Mahasiswa : **Nur Azzura Asyifa**

Nomor Pokok Mahasiswa : **2017031037**

Jurusan : **Matematika**

Fakultas : **Matematika dan Ilmu Pengetahuan Alam**

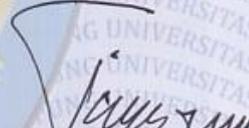
Bandar Lampung, April 2024

**MENYETUJUI**

1. Komisi Pembimbing

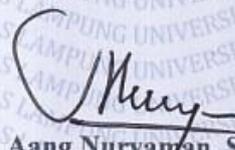


**Dr. Khoirin Nisa, S.Si., M.Si.**  
NIP. 19740726 200003 2 001



**Drs. Tiryono Ruby, M.Sc., Ph.D.**  
NIP. 19620704 198803 1 002

2. Ketua Jurusan Matematika



**Dr. Aang Nuryanjan, S.Si., M.Si.**  
NIP. 19740316 200501 1 001

MENGESAHKAN

1. Tim Penguji

Ketua

: **Dr. Khoirin Nisa, S.Si., M.Si.**

Sekretaris

: **Drs. Tiryono Ruby, M.Sc., Ph.D.**

Penguji

Bukan Pembimbing

: **Drs. Nusyirwan, M.Si.**



Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

**Dr. Eng. Heri Satria, S.Si., M.Si.**

NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi : 1 April 2024

## PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini :

Nama : **Nur Azzura Asyifa**

Nomor Pokok Mahasiswa : **2017031037**

Jurusan : **Matematika**

Judul Skripsi : **PEMODELAN *HYBRID* GSTAR-ANN PADA DATA KELEMBABAN UDARA DI TIGA LOKASI STASIUN PENGAMATAN PROVINSI BANTEN**

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri dan semua tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah karya penulisan ilmiah Universitas Lampung.

Bandar Lampung, 1 April 2024  
Penulis



**Nur Azzura Asyifa**  
**NPM. 2017031037**

## **RIWAYAT HIDUP**

Penulis bernama lengkap Nur Azzura Asyifa dilahirkan di Kota Pandeglang, Provinsi Banten pada tanggal 24 Desember 2001. Penulis merupakan anak tunggal dari pasangan Bapak Nur Alim Akhmad dan Ibu Uswatun Hasanah.

Penulis mengawali pendidikan Taman Kanak-kanak di TK Harapan Islam pada tahun 2006-2008. Kemudian menempuh pendidikan Sekolah Dasar di SDN Labuan 3 pada tahun 2008-2014. Melanjutkan pendidikan Sekolah Menengah Pertama di MTs Mathlaul Anwar Pusat Menes pada tahun 2014-2017 dan melanjutkan pendidikan Sekolah Menengah Atas di MAN 2 Kota Serang pada tahun 2017-2020.

Pada tahun 2020, penulis melanjutkan pendidikan Strata Satu di Jurusan Matematika FMIPA Unila melalui jalur SBMPTN. Selama menjadi mahasiswa, penulis juga aktif dalam organisasi. Pada tahun 2022 penulis menjadi Kepala Biro Kesekretariatan Himpunan Mahasiswa Jurusan Matematika (HIMATIKA). Beberapa kegiatan yang pernah dilakukan penulis semasa kuliah yaitu pada tahun 2021 penulis mengikuti program Kredensial Mikro Mahasiswa Indonesia (KMMI) Kemendikbud yang diselenggarakan oleh Universitas Padjadjaran bekerjasama dengan UNICEF. Pada tahun 2023 penulis melakukan Kerja Praktik (KP) di Badan Pusat Statistika Kabupaten Pandeglang, dan pada tahun yang sama penulis juga melakukan Kuliah Kerja Nyata (KKN) di Desa Way Kepyang, Kecamatan Kedondong, Kabupaten Pesawaran.

## KATA INSPIRASI

*“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya...”*  
**(Q.S Al-Baqarah : 286)**

*“Jangan biarkan kesulitan menguasaimu percayalah bahwa ini adalah malam yang gelap dan hari yang cerah akan datang. Karena sesungguhnya dengan kesulitan aka ada kemudahan”*

**(Q.S Al-Insyirah : 5)**

*“Cukuplah Allah menjadi penolong bagi kami dan Dia adalah sebaik baik pelindung”*

**(Q.S Ali-Imran : 173)**

*“Orang lain ga akan bisa paham struggle dan masa sulitnya kita, yang mereka ingin tahu hanya bagian success stories. Berjuanglah untuk diri sendiri walaupun tidak ada yang tepuk tangan. Kelak diri kita dimasa depan akan sangat bangga dengan apa yang kita perjuangkan hari ini, tetap berjuang ya”*

## **PERSEMBAHAN**

Dengan mengucapkan rasa syukur atas segala puji dan kehadiran Allah SWT yang telah melimpahkan nikmat serta hidayah-Nya sehingga skripsi ini dapat diselesaikan. Tak lupa sholawat serta salam selalu tercurahkan kepada junjungan besar Nabi Muhammad SAW yang telah memberikan tuntunan untuk selalu berada di jalan yang benar. Dengan penuh ketulusan, penulis mempersembahkan karya ini untuk :

### **Kedua Orang Tuaku**

Cinta pertama dan panutanku Ayahanda Nur Alim Akhmad dan pintu surgaku Ibunda Uswatun Hasanah, yang selalu menjadi penyemangat sebagai sandaran terkuat dari kerasnya dunia, yang tiada henti memberikan kasih sayang dengan penuh cinta dan selalu memberikan dukungan material dan mendoakan serta keikhlasannya demi pendidikan putri kecilnya. Terimakasih sudah menjadi orang tua yang sangat amat hebat untukku. Hiduplah lebih lama lagi Ayah dan Ibu harus selalu ada di setiap perjalanan dan pencapaian hidupku.

### **Dosen Pembimbing dan Pembahas**

Terimakasih kepada dosen pembimbing dan pembahas yang telah membantu, memberikan motivasi, memberikan kritik dan saran serta ilmu yang sangat amat berharga.

### **Keluarga Besar dan Sahabat Terbaik**

**Almamater tercinta, Universitas Lampung**

## SANWACANA

Puji syukur kehadirat Allah SWT, atas segala rahmat dan karunia-Nya. Sholawat serta salam selalu tercurahkan kepada junjungan besar Nabi Muhammad SAW, sehingga penulis dapat menyelesaikan skripsi dengan judul **“Pemodelan *Hybrid* GSTAR-ANN Pada Data Kelembaban Udara Di Tiga Lokasi Stasiun Pengamatan Provinsi Banten”**. Penulis menyadari bahwa skripsi ini tidak akan terselesaikan dengan baik tanpa adanya arahan, bimbingan, serta kritik dan saran dari berbagai pihak.

Oleh karena itu, dalam kesempatan ini penulis ingin mengucapkan terima kasih kepada :

1. Ibu Dr. Khorin Nisa, S.Si., M.Si., selaku Dosen Pembimbing I yang senantiasa membimbing dengan sabar, memberikan arahan, bantuan, motivasi, dan saran yang mendukung sehingga penulis dapat menyelesaikan skripsi ini.
2. Bapak Drs. Tiryono Ruby, M.Sc., Ph.D., selaku Dosen Pembimbing II atas bantuan dan bimbingan kepada penulis selama proses penyusunan skripsi ini berlangsung.
3. Bapak Drs. Nusyirwan, M.Si., selaku Dosen Pembahas yang telah memberikan kritik dan saran yang membangun selama proses penyusunan skripsi.
4. Bapak Prof. Drs. Mustofa, M.A., Ph.D., selaku dosen pembimbing akademik.
5. Bapak Dr. Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
6. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Seluruh dosen, staff, karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

8. Kedua orang tuaku tercinta, Ayah Alim dan Ibu Uswah yang tidak pernah lelah untuk selalu mendoakan, memberikan dukungan, pengorbanan, cinta dan kasih sayang serta perhatian demi kesuksesan penulis.
9. Seluruh keluarga besar yang senantiasa memberikan semangat, dukungan, motivasi, dan arahan selama proses perkuliahan.
10. Sahabat penulis (Aghny, Elsa, Icha, Lulu, Metha, Nanda, Nisa, Riska, Sinta, Soraya, Tira, dan Yasmin) yang selalu menjadi sosok rumah tempat melepaskan segala keluh kesah dan menjadi bagian penting dalam perjalanan penulis hingga saat ini.
11. Sahabat seperjuangan (Sinta Andiana, Anggita, Claudya, Demi, dan Asti) yang telah menemani suka dan duka penulis selama proses perkuliahan.
12. Teman-teman pimpinan HIMATIKA dan Biro Kesekretariatan periode 2022 yang memberikan kehidupan selama perkuliahan ini menjadi seru dan asik.
13. Teman-teman KKN Desa Way Kepayang (Agnes, Kezia, Zalma, Agil, Dimas, Aldi) yang telah memberikan dukungan selama proses menyelesaikan skripsi.
14. Teman-teman seperbimbingan (Agis, Hanafi, Hilal, Kak Citra, Maya, Nadia, Nispril, dan Nurul) yang telah kebersamai berjuang pada saat bimbingan.
15. Teman-teman Matematika angkatan 2020, Abang Yunda serta Adik-adik yang telah membantu selama proses perkuliahan.
16. Semua pihak yang tidak dapat disebutkan satu persatu yang telah membantu penulis dalam menyelesaikan skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna dan masih terdapat banyak kekurangan baik dalam penyajian maupun penulisan. Oleh sebab itu, saran dan kritikan yang membangun senantiasa penulis harapkan demi menyempurnakan skripsi ini.

Bandar Lampung, April 2024  
Penulis

**Nur Azzura Asyifa**  
NPM. 2017031037

## DAFTAR ISI

	Halaman
<b>DAFTAR TABEL</b> .....	xvi
<b>DAFTAR GAMBAR</b> .....	xviii
<b>I. PENDAHULUAN</b> .....	1
1.1 Latar Belakang dan Masalah.....	1
1.2 Tujuan Penelitian .....	3
1.3 Manfaat Penelitian .....	3
<b>II. TINJAUAN PUSTAKA</b> .....	4
2.1 Deret Waktu Multivariat .....	4
2.2 <i>Generalized Space Time Autoregressive (GSTAR)</i> .....	4
2.2.1 Model <i>Autoregressive (AR)</i> .....	5
2.2.2 Model <i>Vector Autoregressive (VAR)</i> .....	5
2.2.3 Model <i>Space Time Autoregressive (STAR)</i> .....	6
2.2.4 Model <i>Generalized Space Time Autoregressive (GSTAR)</i> .....	6
2.2.5 Indeks Gini.....	7
2.2.6 Stasioneritas .....	8
2.2.7 Identifikasi Model GSTAR .....	9
2.2.8 Bobot Lokasi .....	9
2.2.9 Estimasi Parameter Model GSTAR .....	11
2.2.10 Uji Kelayakan Model GSTAR.....	13
2.3 <i>Artificial Neural Network (ANN)</i> .....	15
2.3.1 Arsitektur ANN .....	16

2.3.2 Fungsi Aktivasi .....	18
2.3.3 <i>Hyperparameter</i> .....	18
2.3.4 Algoritma <i>Backpropagation</i> .....	19
2.4 <i>Hybrid</i> GSTAR-ANN .....	20
2.5 Validasi Model .....	22
2.6 Perhitungan Nilai Bias .....	23
2.7 Kelembaban Udara.....	24
<b>III. METODE PENELITIAN</b> .....	25
3.1 Waktu dan Tempat Penelitian.....	25
3.2 Data Penelitian .....	25
3.3 Metode Penelitian .....	26
<b>IV. HASIL DAN PEMBAHASAN</b> .....	29
4.1 Deskripsi Data Kelembaban Udara.....	29
4.2 Perhitungan Indeks Gini .....	31
4.3 Uji Kestasioneran.....	31
4.4 Identifikasi Model GSTAR .....	32
4.5 Perhitungan Bobot Lokasi.....	33
4.5.1 Perhitungan Bobot Lokasi Invers Jarak .....	33
4.5.2 Perhitungan Bobot Lokasi Normalisasi Korelasi Silang .....	35
4.6 Estimasi Parameter Model GSTAR .....	36
4.6.1 Estimasi Parameter Model GSTAR dengan Bobot Invers Jarak... 36	
4.6.2 Estimasi Parameter Model GSTAR dengan Bobot Normalisasi Korelasi Silang.....	37
4.7 Uji Kelayakan Model GSTAR .....	38
4.8 Pemilihan Model Terbaik.....	41
4.9 Prediksi dan Peramalan Model GSTAR.....	42
4.10 Ekstraksi Data Residual .....	44
4.11 Prediksi Data dengan <i>Hybrid</i> GSTAR-ANN .....	45

4.12	<i>Splitting Data</i> .....	45
4.13	Membangun Model $Lt'$ ANN Menggunakan Data Prediksi GSTAR ....	46
4.13.1	<i>Hyperparameter Tuning Model <math>Lt'</math> Skema 60% Data Training dan 40% Data Testing</i> .....	47
4.13.2	<i>Hyperparameter Tuning Model <math>Lt'</math> Skema 70% Data Training dan 30% Data Testing</i> .....	48
4.13.3	<i>Hyperparameter Tuning Model <math>Lt'</math> Skema 80% Data Training dan 20% Data Testing</i> .....	48
4.14	Membangun Model $Nt'$ ANN Menggunakan Data Residual GSTAR...	49
4.14.1	<i>Hyperparameter Tuning Model <math>Nt'</math> Skema 60% Data Training dan 40% Data Testing</i> .....	50
4.14.2	<i>Hyperparameter Tuning Model <math>Nt'</math> Skema 70% Data Training dan 30% Data Testing</i> .....	51
4.14.3	<i>Hyperparameter Tuning Model <math>Nt'</math> Skema 80% Data Training dan 20% Data Testing</i> .....	52
4.15	Prediksi menggunakan Model $Lt'$ ANN .....	52
4.16	Prediksi menggunakan Model $Nt'$ ANN.....	53
4.17	Prediksi Model <i>Hybrid</i> GSTAR-ANN .....	54
4.18	Evaluasi Hasil Prediksi .....	55
4.19	Peramalan Model <i>Hybrid</i> .....	56
4.19.1	Peramalan Model $Lt'$ dengan Prediksi GSTAR.....	56
4.19.2	Peramalan Model $Nt'$ dengan Residual GSTAR .....	57
4.19.3	Peramalan Model <i>Hybrid</i> GSTAR-ANN.....	58
4.20	Nilai Bias Model GSTAR dan Model <i>Hybrid</i> GSTAR-ANN.....	63
<b>V.</b>	<b>KESIMPULAN</b> .....	<b>65</b>
	<b>DAFTAR PUSTAKA</b> .....	<b>66</b>
	<b>LAMPIRAN</b> .....	<b>69</b>

## DAFTAR TABEL

Tabel	Halaman
1. Kriteria Berdasarkan Nilai MAPE .....	23
2. Statistika Deskriptif Data Kelembaban Udara Ketiga Lokasi.....	29
3. Nilai Hasil Perhitungan Indeks Gini Ketiga Lokasi.....	31
4. Uji ADF Data Kelembaban Udara Ketiga Lokasi.....	32
5. Nilai AIC untuk Model VAR.....	33
6. Jarak Antarlokasi Ketiga Stasiun .....	34
7. Estimasi Parameter Dengan Bobot Lokasi Invers Jarak .....	36
8. Estimasi Parameter Dengan Bobot Lokasi Normalisasi Korelasi Silang.....	37
9. Hasil Uji <i>Ljung-Box</i> dengan <i>P-Value</i> .....	39
10. Uji Normalitas Residual Model .....	40
11. Nilai MSE dan MAPE.....	42
12. Hasil Peramalan Model GSTAR .....	44
13. Data Residual Model GSTAR.....	45
14. <i>Splitting</i> Data <i>Training</i> dan Data <i>Testing</i> .....	46
15. Hasil <i>Hyperparameter Tuning</i> untuk Model $L'_t$ skema 60% 40%.....	47

16. Hasil <i>Hyperparameter Tuning</i> untuk Model $L'_t$ skema 70% 30%.....	48
17. Hasil <i>Hyperparameter Tuning</i> untuk Model $L'_t$ skema 80% 20%.....	49
18. Hasil <i>Hyperparameter Tuning</i> untuk Model $N'_t$ skema 60% 40%.....	50
19. Hasil <i>Hyperparameter Tuning</i> untuk Model $N'_t$ skema 70% 30%.....	51
20. Hasil <i>Hyperparameter Tuning</i> untuk Model $N'_t$ skema 80% 20%.....	52
21. Evaluasi Hasil Prediksi .....	56
22. Hasil Peramalan Model <i>Hybrid</i> GSTAR-ANN.....	62
23. Perbandingan Data <i>Ter-Update</i> (Validasi Silang), Data Peramalan Model GSTAR dan Data Peramalan Model <i>Hybrid</i> GSTAR-ANN.....	63
24. Perhitungan Nilai Bias .....	64

## DAFTAR GAMBAR

Gambar	Halaman
1. Arsitektur Jaringan Syaraf Tiruan .....	16
2. Struktur <i>Single Layer Network</i> .....	17
3. Struktur <i>Single Layer Network</i> .....	17
4. Diagram Alur Pembentukan Model <i>Hybrid</i> GSTAR-ANN.....	28
5. Plot Data Kelembaban Udara Ketiga Lokasi Stasiun.....	30
6. Q-Q Plot Residual Bobot Invers Jarak dan Bobot Normalisasi Korelasi Silang .....	40
7. Visualisasi Hasil Peramalan Model GSTAR .....	43
8. Visualisasi Prediksi Model $L'_t$ ANN .....	53
9. Visualisasi Prediksi Model $N'_t$ ANN.....	54
10. Visualisasi Prediksi Model <i>Hybrid</i> .....	55
11. Visualisasi Hasil Peramalan Model $L'_t$ .....	57
12. Visualisasi Hasil Peramalan Model $N'_t$ .....	58
13. Visualisasi Hasil Peramalan Model <i>Hybrid</i> GSTAR-ANN Skema 60% Data <i>Traing</i> dan 40% Data <i>Testing</i> .....	59

14. Visualisasi Hasil Peramalan Model <i>Hybrid</i> GSTAR-ANN Skema 70%	
Data <i>Training</i> dan 30% Data <i>Testing</i> .....	60
15. Visualisasi Hasil Peramalan Model <i>Hybrid</i> GSTAR-ANN Skema 80%	
Data <i>Training</i> dan 20% Data <i>Testing</i> .....	61

## I. PENDAHULUAN

### 1.1 Latar Belakang dan Masalah

Urutan pengamatan yang dikumpulkan dalam kurun waktu tertentu dengan periode waktu yang sama disebut *time series* (Box, *et al.*, 1994). Waktu yang dipakai dapat berupa hari, minggu, bulan, tahun dan sebagainya. Berdasarkan jumlah variabel yang diamati, analisis *time series* memiliki dua jenis model yakni model univariat hanya menggunakan satu variabel dan model multivariat menggunakan lebih dari satu variabel. Seiring perkembangannya, analisis *time series* tidak hanya berdimensi waktu, *time series* juga dapat berdimensi ruang dan waktu atau *space time* (Wei, 2006).

Pada tahun 1980, Pfeifer & Deutsch mengenalkan model *Space Time Autoregressive* (STAR) sebagai model *space time*. Kelemahan model STAR yaitu bahwa model STAR hanya menganggap bahwa parameter *autoregressive* bersifat homogen untuk semua lokasi, sehingga model STAR tidak fleksibel saat dihadapkan dengan lokasi yang bersifat heterogen. Selanjutnya, Borovkova dkk., pada tahun 2002 mengembangkan model *Generalized Space Time Autoregressive* (GSTAR) untuk mengatasi masalah tersebut. Model GSTAR merupakan model *space time* yang memiliki parameter *autoregressive* berbeda untuk setiap lokasi atau bersifat heterogen (Ruchjana, 2002).

Model GSTAR memiliki keterbatasan yaitu tidak mampu memodelkan *time series* yang nonlinear. Hal ini bisa diatasi dengan menerapkan model *hybrid*. Model *hybrid* merupakan suatu metode yang menggabungkan dua atau lebih model dalam satu sistem. Model *hybrid* bekerja dengan menggabungkan model linear

dan nonlinear (Zhang, 2001). Salah satu model *time series* nonlinear yang dapat digunakan adalah model *Artificial Neural Network* (ANN).

Model ANN merupakan metode yang menggunakan cara kerja yang mirip dengan jaringan syaraf manusia. Berbagai kasus regresi, klasifikasi dan juga *time series* sudah banyak menggunakan model ANN. Keuntungan dari model ANN adalah kemampuan pemodelan nonlinear yang fleksibel. Keterbatasan yang dimiliki oleh model GSTAR dapat diatasi dengan mengkombinasikan dengan model ANN agar meningkatkan dalam melakukan peramalan. Walaupun hasil peramalan yang didapatkan belum tentu sesuai dengan keadaan aktualnya, diharapkan kombinasi keduanya dapat memaksimalkan akurasi hasil peramalan.

Salah satu implementasi dari metode *hybrid* GSTAR-ANN yaitu untuk meramalkan data kelembaban udara. Menurut BMKG (2006), kelembaban udara merupakan besarnya kadar uap air yang terkandung oleh udara. Oleh karena itu peramalan data kelembaban udara dibutuhkan untuk memperkirakan data kelembaban udara di masa yang akan datang.

Beberapa penelitian yang pernah dilakukan dengan menggunakan metode GSTAR, metode ANN, ataupun metode *hybrid* GSTAR-ANN dilakukan oleh Agustina, dkk. (2022) yang menggunakan pemodelan GSTAR-Filter Kalman dengan pembobotan invers jarak dan normalisasi silang. Penelitian lain juga pernah dilakukan oleh Amaly, dkk. (2022) untuk melakukan peramalan nilai Inflasi di Indonesia dengan melakukan perbandingan metode ANN *Backpropagation* dan ARMA yang dapat diambil kesimpulan bahwa dengan menggunakan metode ANN *Backpropagation* lebih optimal untuk memprediksi inflasi di Indonesia. Penelitian lainnya juga pernah dilakukan oleh Dana (2018) untuk meramalkan data *space time* dengan efek variasi kalender menggunakan model *hybrid* GSTARX-ANN dan dapat disimpulkan bahwa penggunaan model *hybrid* GSTARX-ANN menghasilkan kesalahan ramalan yang lebih kecil dalam meramalkan data.

Berdasarkan pemaparan di atas, dalam penelitian ini akan dikaji lebih lanjut penerapan metode *hybrid* GSTAR-ANN. Penulis akan melakukan pemodelan dan peramalan data kelembaban udara di tiga lokasi stasiun pengamatan yang berada di Provinsi Banten yaitu Stasiun Klimatologi Tangerang Selatan, Stasiun Meteorologi Serang, dan Stasiun Geofisika Tangerang dengan menggunakan metode *hybrid* GSTAR-ANN.

## 1.2 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah menentukan model *hybrid* GSTAR-ANN yang sesuai dan mendapatkan hasil peramalan pada data kelembaban udara di tiga lokasi stasiun pengamatan yang berada di Provinsi Banten untuk periode yang akan datang.

## 1.3 Manfaat Penelitian

Manfaat yang diharapkan dalam penelitian ini adalah sebagai berikut :

1. Menghasilkan model *hybrid* GSTAR-ANN yang dapat digunakan untuk meramalkan data kelembaban udara di tiga lokasi stasiun pengamatan yang berada di Provinsi Banten untuk periode mendatang.
2. Memberikan pengetahuan ataupun informasi bagi penulis maupun pembaca.
3. Dapat menjadi referensi bagi peneliti selanjutnya tentang metode *hybrid* GSTAR-ANN maupun tentang prediksi data kelembaban udara.

## II. TINJAUAN PUSTAKA

### 2.1 Deret Waktu Multivariat

Analisis deret waktu merupakan pengamatan pada satu atau lebih variabel yang diambil secara berurutan dari waktu ke waktu (Wei, 2006). Data deret waktu adalah serangkaian data yang dikumpulkan dan kemudian disusun berdasarkan urutan waktu dalam selang waktu yang sama (Cryer, 2008). Sehingga dapat digunakan untuk peramalan data dimasa yang akan datang, misalnya peramalan pada data harga saham, data inflasi, data kelembaban udara, dan lain sebagainya.

Menurut Wei (2006), berdasarkan variabel yang diamati analisis deret waktu diklasifikasikan menjadi dua jenis, yaitu deret waktu univariat dan deret waktu multivariat. Deret waktu univariat hanya menggunakan satu variabel sedangkan deret waktu multivariat menggunakan lebih dari satu variabel. Untuk menghasilkan pemodelan atau peramalan yang lebih akurat, diperlukan pengujian dengan menentukan dan menemukan interaksi yang ada pada satu atau lebih variabel. Proses pemodelan deret waktu multivariat sama dengan pemodelan deret waktu univariat.

### 2.2 *Generalized Space Time Autoregressive (GSTAR)*

Model GSTAR diperkenalkan pertama kali oleh Borovkova dkk., (2002). GSTAR merupakan generalisasi dari model STAR dan juga merupakan spesifikasi dari model *Vector Autoregressive* (VAR) (Ruchjana, 2002).

### 2.2.1 Model *Autoregressive* (AR)

Model AR merupakan model yang mengasumsikan suatu kejadian sebelumnya mempengaruhi kejadian saat ini dalam data deret waktu. Menurut Wei (2006), Model AR( $p$ ) secara umum dapat dinyatakan pada persamaan (2.1).

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t \quad (2.1)$$

dengan :

- $Z_t$  = data pada waktu ke- $t$ ,
- $Z_{t-1}, \dots, Z_{t-p}$  = nilai masa lalu dari deret waktu yang bersangkutan,
- $\phi_i$  = parameter AR pada lag ke- $i$ ,
- $\varepsilon_t$  = nilai *error* pada waktu ke- $t$ ,
- $p$  = order AR.

### 2.2.2 Model *Vector Autoregressive* (VAR)

Model VAR merupakan suatu pendekatan peramalan kuantitatif yang biasanya digunakan pada deret waktu peubah ganda, artinya model ini menggambarkan hubungan antar pengamatan pada peubah itu sendiri di waktu sebelumnya dan juga hubungannya dengan pengamatan pada peubah lain pada periode sebelumnya. Menurut Wei (2006), VAR( $p$ ) secara umum dapat dinyatakan pada persamaan (2.2).

$$\mathbf{Z}_t = \Phi_1 \mathbf{Z}_{t-1} + \Phi_2 \mathbf{Z}_{t-2} + \dots + \Phi_p \mathbf{Z}_{t-p} + \varepsilon_t \quad (2.2)$$

dengan :

- $\mathbf{Z}_t$  = vektor pengamatan pada waktu ke- $t$  lokasi ke- $n$  berukuran ( $n \times 1$ ),
- $\Phi_p$  = matriks parameter *vector autoregressive* orde ke- $p$  berukuran ( $n \times n$ ),
- $\varepsilon_t$  = vektor *error* berukuran ( $n \times 1$ ), dimana  $\varepsilon_t \sim N_p(\mathbf{0}, \Sigma)$ .

### 2.2.3 Model *Space Time Autoregressive* (STAR)

Model STAR diperkenalkan oleh Cliff dan Ord (1973). Serupa dengan model VAR, pada model STAR dicirikan oleh ketergantungan linear dalam ruang dan waktu. Satu hal yang membedakannya dari model VAR adalah pada model STAR terdapat ketergantungan spasial yang ditunjukkan dengan adanya matriks pembobot. Model STAR dengan *autoregressive* orde  $p$  dan orde spasial  $\lambda_1, \lambda_2, \dots, \lambda_p$  dinotasikan dengan model STAR  $(p, \lambda_1, \lambda_2, \dots, \lambda_p)$  dapat dituliskan pada persamaan (2.3).

$$\mathbf{Z}_t = \sum_{k=1}^p \sum_{l=1}^{\lambda_p} \Phi_{kl} \mathbf{W}^l \mathbf{Z}_{(t-k)} + \boldsymbol{\varepsilon}_t \quad (2.3)$$

dengan :

- $\mathbf{Z}_t$  = vektor pengamatan berukuran  $(N \times l)$  pada waktu ke- $t$ ,
- $\Phi_{kl}$  = matriks parameter *autoregressive* pada lag waktu  $k$  dan orde spasial  $l$ ,
- $\mathbf{W}^{(l)}$  = matriks pembobot pada orde spasial  $l$  dengan ukuran  $(N \times N)$ ,
- $\boldsymbol{\varepsilon}_t$  = vektor *error* pada waktu ke- $t$  berukuran  $(N \times 1)$ .

### 2.2.4 Model *Generalized Space Time Autoregressive* (GSTAR)

Nilai parameter *autoregressive* merupakan perbedaan yang sangat mendasar antara model STAR dan Model GSTAR. Model STAR memiliki nilai parameter yang sama untuk setiap lokasi sehingga memiliki kekurangan yang tidak fleksibel saat digunakan untuk setiap lokasi yang berbeda. Sedangkan, model GSTAR memiliki nilai parameter berbeda untuk setiap lokasi, sehingga memiliki karakteristik yang bersifat heterogen (Wutsqa, dkk., 2010).

Model GSTAR dengan *autoregressive* orde  $p$  dan orde spasial  $\lambda_1, \lambda_2, \dots, \lambda_k$  dinotasikan dengan model GSTAR  $(p, \lambda_1, \lambda_2, \dots, \lambda_k)$  dapat dituliskan pada persamaan (2.4).

$$\mathbf{Z}_t = \sum_{k=1}^p \left[ \Phi_{k0} \mathbf{Z}_{(t-k)} + \sum_{l=1}^{\lambda_k} \Phi_{kl} \mathbf{W}^l \mathbf{Z}_{(t-k)} \right] + \boldsymbol{\varepsilon}_t \quad (2.4)$$

dengan :

- $\mathbf{Z}_t$  = vektor pengamatan berukuran  $(N \times l)$  pada waktu ke- $t$ ,
- $l$  = orde spasial dimana  $l = \lambda_1, \lambda_2, \dots, \lambda_k$ ,
- $\Phi_{k0}$  = matriks parameter *autoregressive* pada lag waktu  $k$  dan orde spasial 0 dengan elemen *diag*  $(\phi_{k0}^1, \dots, \phi_{k0}^N)$ ,
- $\Phi_{kl}$  = matriks parameter *autoregressive* pada lag waktu  $k$  dan orde spasial  $l$  dengan elemen *diag*  $(\phi_{kl}^1, \dots, \phi_{kl}^N)$ ,
- $\mathbf{W}^{(l)}$  = matriks pembobot pada orde spasial  $l$  dengan ukuran  $(N \times N)$  yang dipilih agar memenuhi syarat  $w_{ii}^{(l)} = 0$  dan  $w_{ij}^{(l)} = 1$ ,
- $\boldsymbol{\varepsilon}_t$  = vektor *error* pada waktu  $t$  yang diasumsikan bebas dan normal dengan rata-rata nol dan variansi yang konstan.

### 2.2.5 Indeks Gini

Uji heterogenitas lokasi dilakukan untuk menentukan apakah lokasi bersifat homogen atau heterogen. Indeks Gini diperkenalkan oleh seorang statistikawan asal Italia, Corrado Gini (1884-1965). Indeks Gini digunakan untuk dapat menganalisis keheterogenan lokasi (Aufa, dkk., 2022). Nilai indeks Gini berkisar antara 0 sampai dengan 1, semakin tinggi nilainya maka akan semakin heterogen lokasi penelitian (Risnandar & Achmad, 2023).

Rumus yang dapat digunakan untuk mencari nilai indeks Gini dapat dituliskan pada persamaan (2.5).

$$G_i = 1 + \frac{1}{n_i} - \frac{2}{n_i^2 \bar{y}_i} \sum_{t=1}^{n_i} y_i \quad (2.5)$$

dengan :

- $G_i$  = nilai indeks Gini,
- $n_i$  = jumlah data yang diamati,

- $\bar{y}_i$  = rata-rata nilai variabel yang diamati,  
 $y_i$  = nilai variabel yang diamati.

## 2.2.6 Stasioneritas

Menurut Montgomery, *et al.* (2008), kestasioneran merupakan syarat penting dalam analisis deret waktu. Kestasioneran menunjukkan kestabilan pada data, artinya tidak ada peningkatan atau penurunan pada data deret waktu maka dianggap stasioner. Ada beberapa uji untuk melihat kestasioneran data deret waktu salah satunya yaitu uji akar unit (*unit root test*). Menurut Wei (2006), uji *Augmented Dickey Fuller* (ADF) merupakan salah satu uji stasioneritas yang digunakan untuk menentukan apakah data deret waktu stasioner atau tidak.

Tahapan uji ADF adalah sebagai berikut :

1. Hipotesis :

$$H_0: \phi = 1 \text{ data tidak stasioner}$$

$$H_1: \phi \neq 1 \text{ data stasioner}$$

2. Taraf Signifikansi :  $\alpha = 5\%$

3. Statistik Uji :

$$ADF_{test} = \frac{\hat{\phi} - 1}{SE(\hat{\phi})} \quad (2.6)$$

dengan :

$$\hat{\phi} = \frac{\sum_{t=1}^n Z_{t-1} Z_t}{\sum_{t=1}^n Z_{t-1}^2}$$

$$SE(\hat{\phi}) = [\hat{\sigma}_e^2 (\sum_{t=1}^n Z_{t-1}^2)]^{\frac{1}{2}}$$

$$\hat{\phi}_e^2 = \sum_{t=1}^n \frac{(Z_t - \hat{\phi} Z_{t-1})^2}{n-1}$$

4. Daerah Kritis

Dikatakan tolak  $H_0$  jika  $ADF_{test} \leq ADF_{(\alpha, n)}$  atau  $p\text{-value} \leq \alpha$

5. Keputusan

6. Kesimpulan

Jika fluktuasi data deret waktu berada di sekitar suatu nilai rata-rata yang konstan, maka data dapat dikatakan stasioner. Jika data tidak stasioner dalam rata-rata, maka dapat dilakukan proses pembedaan (*differencing*).

### 2.2.7 Identifikasi Model GSTAR

Model GSTAR merupakan model peramalan deret waktu sehingga proses identifikasi model meliputi penentuan orde *autoregressive* dan orde spasial (Wutsqa, dkk., 2012). Orde spasial pada model GSTAR dibatasi pada orde 1, hal ini disebabkan karena pada model orde spasial yang lebih tinggi akan sulit untuk diinterpretasikan (Wutsqa, dkk., 2010). Orde *autoregressive* dapat ditentukan berdasarkan nilai *Akaike Information Criterion* (AIC). Suatu model dikatakan baik jika diperoleh nilai AIC yang paling kecil. Perhitungan nilai AIC dapat dituliskan pada persamaan (2.7) (Tsay, 2005):

$$AIC_i = \ln \left( \frac{\sum_{i=1}^n \hat{e}_i^2}{T} \right) + \frac{2m^2 i}{T} \quad (2.7)$$

dengan :

- $I$  = 0,1, ...,  $p$ ;  $p$  = orde *autoregressive* tentatif model,
- $M$  = jumlah parameter yang diestimasi dalam model,
- $T$  = jumlah pengamatan,
- $\hat{e}_i^2$  = kuadrat residual dari model vektor *autoregressive* ke- $i$

### 2.2.8 Bobot Lokasi

Menurut Mansoer, dkk., (2016), hubungan spasial pada model GSTAR dapat dinyatakan dalam matriks pembobot.

### 2.2.8.1 Bobot Lokasi Invers Jarak

Pembobotan menggunakan metode bobot *invers* jarak dilakukan berdasarkan jarak yang sebenarnya (Islamiyah, dkk., 2018). Perhitungan jarak antar lokasi ini dapat menggunakan garis lintang dan garis bujur koordinat yang diamati. Perhitungan nilai dari bobot *invers* jarak dapat dituliskan pada persamaan (2.8)

$$W_{ij} = \frac{(d_{i,j})^{-1}}{\sum_{j \neq i} (d_{i,j})^{-1}} \quad (2.8)$$

dengan :

$$(d_{i,j})^{-1} = \begin{cases} \frac{1}{d_{i,j}}; i \neq j \\ 0; i = j \end{cases} (i, j = 1, 2, \dots, n)$$

$$d_{i,j} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}, i \neq j$$

dimana,  $d_{i,j}$  merupakan jarak dari lokasi  $i$  ke  $j$ , dengan  $(x_i, x_j)$  adalah koordinat dari garis lintang dan  $(y_i, y_j)$  dari garis bujur.

### 2.2.8.2 Bobot Lokasi Normalisasi Korelasi Silang

Pembobot dengan menggunakan bobot normalisasi korelasi silang ini tidak memberikan syarat aturan tertentu, seperti bergantung pada jarak antar lokasi. Secara umum bobot normalisasi korelasi silang antar lokasi ke- $i$  dan ke- $j$  pada lag waktu ke- $k$  dapat dituliskan pada persamaan (2.9) (Islamiyah, dkk., 2018).

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{\sigma_i \sigma_j}, k = 0, \pm 1, \pm 2, \dots \quad (2.9)$$

dengan :

$$\gamma_{ij}(k) = \text{korelasi silang antar pengamatan di lokasi ke-}i \text{ dan ke-}j \text{ pada lag waktu ke-}k,$$

$$\sigma_i \sigma_j = \text{Standar deviasi dari pengamatan di lokasi ke-}i \text{ dan ke-}j.$$

Nilai penduga korelasi pada data sampel dapat dihitung dengan rumus yang dituliskan pada persamaan (2.10).

$$r_{ij}(k) = \frac{\sum_{t=k+1}^n [Z_i(t) - \bar{Z}_i][Z_j(t-k) - \bar{Z}_j]}{\sqrt{(\sum_{t=1}^n [Z_i(t) - \bar{Z}_i])^2 (\sum_{t=1}^n [Z_j(t) - \bar{Z}_j])^2}} \quad (2.10)$$

dengan :

- $\bar{Z}_i$  = nilai rata-rata sampel pada vektor deret waktu ke- $i$ ,
- $\bar{Z}_j$  = nilai rata-rata sampel pada vektor deret waktu ke- $j$ ,
- $n$  = jumlah data yang diamati,
- $k$  = lag waktu.

Penentuan bobot lokasi normalisasi korelasi silang dapat dituliskan pada persamaan (2.11) (Siagian, dkk., 2017).

$$W_{ij}(k) = \frac{r_{ij}(k)}{\sum_{j \neq i} |r_{ij}(k)|} \quad (2.11)$$

dimana  $i \neq j$  dan  $\sum_{j \neq i} |W_{ij}| = 1$

### 2.2.9 Estimasi Parameter Model GSTAR

Model GSTAR merupakan suatu model linear dan parameter *autoregressive*-nya dapat diestimasi dengan metode *least square*. Model GSTAR pada persamaan (2.4) dapat dinyatakan dalam bentuk matriks pada persamaan (2.12) (Borovkova, dkk., 2002).

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \\ \vdots \\ Z_N(t) \end{bmatrix} = \begin{bmatrix} \phi_{k0}^{(1)} & 0 & \cdots & 0 \\ 0 & \phi_{k0}^{(2)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \phi_{k0}^{(N)} \end{bmatrix} \begin{bmatrix} Z_1(t-k) \\ Z_2(t-k) \\ \vdots \\ Z_N(t-k) \end{bmatrix} + \begin{bmatrix} \phi_{kl}^{(1)} & 0 & \cdots & 0 \\ 0 & \phi_{kl}^{(2)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \phi_{kl}^{(N)} \end{bmatrix} \begin{bmatrix} Z_1(t-k) \\ Z_2(t-k) \\ \vdots \\ Z_N(t-k) \end{bmatrix} + \begin{bmatrix} \varepsilon_1(t) \\ \varepsilon_2(t) \\ \vdots \\ \varepsilon_N(t) \end{bmatrix} \quad (2.12)$$

Jika  $V_i(t) = \sum_{j=1}^N w_{ij} Z_j(t)$ , maka persamaan (2.12) dapat ditulis pada persamaan (2.13).

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \\ \vdots \\ Z_N(t) \end{bmatrix} = \begin{bmatrix} \phi_{k0}^{(1)} & 0 & \cdots & 0 \\ 0 & \phi_{k0}^{(2)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \phi_{k0}^{(N)} \end{bmatrix} \begin{bmatrix} Z_{1(t-k)} \\ Z_{2(t-k)} \\ \vdots \\ Z_{N(t-k)} \end{bmatrix} + \begin{bmatrix} \phi_{kl}^{(1)} & 0 & \cdots & 0 \\ 0 & \phi_{kl}^{(2)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \phi_{kl}^{(N)} \end{bmatrix} \begin{bmatrix} V_{1(t-k)} \\ V_{2(t-k)} \\ \vdots \\ V_{N(t-k)} \end{bmatrix} + \begin{bmatrix} \varepsilon_1(t) \\ \varepsilon_2(t) \\ \vdots \\ \varepsilon_N(t) \end{bmatrix} \quad (2.13)$$

Bentuk yang lebih sederhana dari persamaan (2.13) dapat dinyatakan pada persamaan (2.14).

$$\begin{bmatrix} Z_1(t) \\ Z_2(t) \\ \vdots \\ Z_N(t) \end{bmatrix} = \begin{bmatrix} Z_{1(t-k)} & V_{1(t-k)} & \cdots & 0 & 0 \\ 0 & 0 & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & Z_{N(t-k)} & V_{N(t-k)} \end{bmatrix} \begin{bmatrix} \phi_{k0}^{(1)} \\ \phi_{kl}^{(1)} \\ \vdots \\ \phi_{k0}^{(N)} \\ \phi_{kl}^{(N)} \end{bmatrix} + \begin{bmatrix} \varepsilon_1(t) \\ \varepsilon_2(t) \\ \vdots \\ \varepsilon_N(t) \end{bmatrix} \quad (2.14)$$

Persamaan (2.14) dapat ditulis dalam bentuk model linier di persamaan (2.15).

$$\begin{aligned} \mathbf{z} &= \mathbf{X}\boldsymbol{\phi} + \boldsymbol{\varepsilon} \\ \boldsymbol{\varepsilon} &= \mathbf{z} - \mathbf{X}\boldsymbol{\phi} \end{aligned} \quad (2.15)$$

Adapun estimasi parameter menggunakan metode *Ordinary Least Square* (OLS) adalah dapat ditulis pada persamaan (2.16).

$$\begin{aligned} \boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon} &= (\mathbf{z} - \mathbf{X}\boldsymbol{\phi})^T (\mathbf{z} - \mathbf{X}\boldsymbol{\phi}) \\ &= (\mathbf{z}^T - \mathbf{X}^T \boldsymbol{\phi}^T) (\mathbf{z} - \mathbf{X}\boldsymbol{\phi}) \\ &= \mathbf{z}^T \mathbf{z} - \mathbf{z}^T \mathbf{X}\boldsymbol{\phi} - \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{z} + \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{X}\boldsymbol{\phi} \\ &= \mathbf{z}^T \mathbf{z} - (\mathbf{z}^T \mathbf{X}\boldsymbol{\phi})^T - \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{z} + \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{X}\boldsymbol{\phi} \\ &= \mathbf{z}^T \mathbf{z} - \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{z} - \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{z} + \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{X}\boldsymbol{\phi} \\ &= \mathbf{z}^T \mathbf{z} - 2\boldsymbol{\phi}^T \mathbf{X}^T \mathbf{z} + \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{X}\boldsymbol{\phi} \end{aligned} \quad (2.16)$$

Untuk meminimumkan  $\boldsymbol{\varepsilon}_i^T \boldsymbol{\varepsilon}_i$ , maka  $\boldsymbol{\varepsilon}_i^T \boldsymbol{\varepsilon}_i$  dapat diturunkan terhadap  $\boldsymbol{\phi}$  sehingga diperoleh persamaan (2.17).

$$\begin{aligned}
\frac{\partial \boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon}}{\partial \boldsymbol{\phi}} &= \frac{\partial \mathbf{z}^T \mathbf{z}}{\partial \boldsymbol{\phi}} - 2 \frac{\partial \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{z}}{\partial \boldsymbol{\phi}} + \frac{\partial \boldsymbol{\phi}^T \mathbf{X}^T \mathbf{X} \boldsymbol{\phi}}{\partial \boldsymbol{\phi}} \\
&= 0 - 2\mathbf{X}^T \mathbf{z} + \mathbf{X}^T \mathbf{X} \boldsymbol{\phi} + (\mathbf{X}^T \mathbf{X} \boldsymbol{\phi}^T)^T \\
&= -2\mathbf{X}^T \mathbf{z} + 2\mathbf{X}^T \mathbf{X} \boldsymbol{\phi}
\end{aligned} \tag{2.17}$$

Persamaan (2.17) dapat ditulis sebagai berikut :

$$\begin{aligned}
\frac{\partial \boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon}}{\partial \boldsymbol{\phi}} &= 0 \\
-2\mathbf{X}^T \mathbf{z} + 2\mathbf{X}^T \mathbf{X} \boldsymbol{\phi} &= 0 \\
\mathbf{X}^T \mathbf{X} \boldsymbol{\phi} &= \mathbf{X}^T \mathbf{z} \\
(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} \boldsymbol{\phi} &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{z} \\
\boldsymbol{\phi} &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{z}
\end{aligned} \tag{2.18}$$

Sehingga diperoleh estimator OLS yang ditulis pada persamaan (2.19)

$$\hat{\boldsymbol{\phi}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{z} \tag{2.19}$$

dengan :

- $\hat{\boldsymbol{\phi}}$  = vektor dari parameter,
- $\mathbf{X}$  = matriks variabel prediktor,
- $\mathbf{z}$  = vektor observasi dari variabel respon.

### 2.2.10 Uji Kelayakan Model GSTAR

Setelah memperoleh estimasi parameter model GSTAR, langkah selanjutnya yaitu menguji kelayakan model. Uji kelayakan model dilakukan untuk menentukan apakah model yang dihasilkan dapat digunakan untuk peramalan. Dalam model deret waktu multivariat terdapat ua asumsi model yaitu residual bersifat *white noise* dan berdistribusi normal multivariat.

### 2.2.10.1 Uji White Noise

Menurut Hanke & Wichern (2005), uji *Ljung-Box* dapat digunakan untuk memeriksa asumsi *white noise*. Model GSTAR dapat dikatakan layak jika nilai residual memenuhi asumsi *white noise*. Tujuan dari asumsi *white noise* ini adalah untuk mengetahui residual yang tidak berkorelasi satu sama lain. Langkah-langkah yang digunakan dalam uji *Ljung-Box* adalah sebagai berikut :

1. Hipotesis

$H_0$ : tidak ada korelasi dari residual (bersifat *white noise*)

$H_1$ : ada korelasi dari residual (tidak bersifat *white noise*)

2. Taraf Signifikansi :  $\alpha = 5\%$

3. Statistik Uji :

$$Q = n(n + 2) \sum_{k=1}^K \frac{\rho_k^2}{n - k} \quad (2.20)$$

dengan :

$Q$  = statistik uji *Ljung-Box*

$n$  = jumlah data

$K$  = *lag* maksimum

$\rho_k^2$  = Koefisien autokorelasi pada *lag* ke- $k$

4. Daerah Kritis

Dikatakan tolak  $H_0$  jika  $|Q| \geq \chi_{\alpha; (K-p)}^2$  atau  $p\text{-value} \leq \alpha$

5. Keputusan

6. Kesimpulan.

### 2.2.10.2 Uji Normalitas Multivariat

Untuk menentukan apakah residual model GSTAR yang didapat berdistribusi normal maka dilakukan uji normalitas residual. Uji normalitas residual dapat dilakukan dengan melihat *Quantile-Quantile Plot* (*Q-Q Plot*). Menurut Nasrum, (2018). pada *Q-Q Plot* jika sebaran data berada dekat pada garis, maka dapat

dikatakan residual berdistribusi normal. Uji normalitas juga dapat dilakukan dengan uji Kolmogorov-Smirnov. Langkah-langkah yang dilakukan untuk uji Kolmogorov-Smirnov adalah sebagai berikut:

1. Hipotesis

$H_0$ : residual berdistribusi normal

$H_1$ : residual tidak berdistribusi normal

2. Taraf Signifikansi :  $\alpha = 5\%$

3. Statistik Uji :

$$D = \max|F_0(X) - S_n(X)| \quad (2.21)$$

dengan :

$F_0(X)$  = fungsi distribusi frekuensi kumulatif

$S_n(X)$  = probabilitas kumulatif dari distribusi normal

4. Daerah Kritis

Dikatakan tolak  $H_0$  jika  $D \geq D_{n(\alpha)}$  atau  $p\text{-value} \leq \alpha$

5. Keputusan

6. Kesimpulan

### 2.3 *Artificial Neural Network* (ANN)

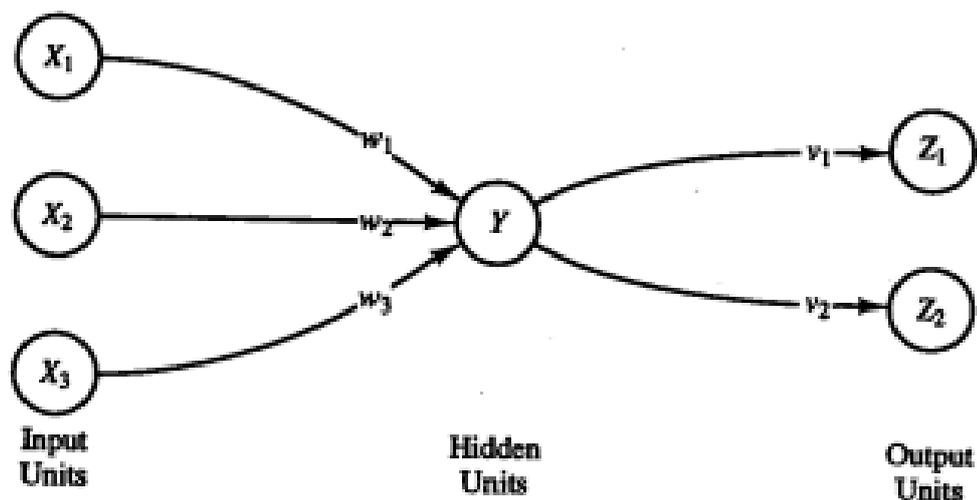
Jaringan Syaraf Tiruan (JST) atau *Artificial Neural Network* (ANN) merupakan sebuah sistem cerdas yang sudah banyak digunakan dalam berbagai bidang diantaranya *medical diagnostic*, peramalan, dan lain sebagainya. ANN mempunyai cara kerja dan karakteristik yang mirip dengan jaringan syaraf pada manusia (Insany, dkk., 2023).

Neuron, unit, sel atau node merupakan elemen-elemen pemrosesan sederhana pada ANN (Khashei & Bijari, 2010). Setiap neuron terhubung dengan neuron yang lain melalui saluran komunikasi yang direpresentasikan dengan *weight*/bobot. Metode untuk menentukan nilai *weight* disebut dengan *training*, *learning*, atau algoritma. Fungsi aktivasi digunakan oleh setiap neuron pada *input* jaringan untuk menentukan *output*. Neuron-neuron dalam ANN disusun dalam

grup atau kelompok yang disebut dengan *layer* atau lapis. Secara umum terdapat tiga lapis yang membentuk *neuron network* yaitu lapis *input*, lapis tersembunyi (*hidden layer*) dan lapis *output*.

### 2.3.1 Arsitektur ANN

*Net architecture* merupakan pengelompokkan *neuron* ke dalam lapisan dan pola hubungan antar lapisan. Berikut merupakan arsitektur jaringan syaraf sederhana yang disajikan pada Gambar 1 (Fausett, 1994).



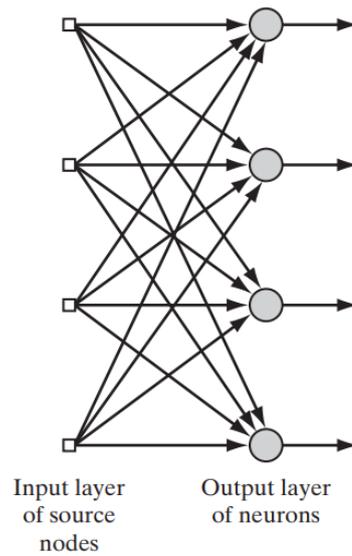
Gambar 1. Arsitektur Jaringan Syaraf Tiruan

Arsitektur ANN memiliki pola hubungan yaitu *single layer* dan *multiplayer* :

#### a. *Single Layer Network*

*Single layer network* mempunyai satu lapisan bobot koneksi (Fausset, 1994).

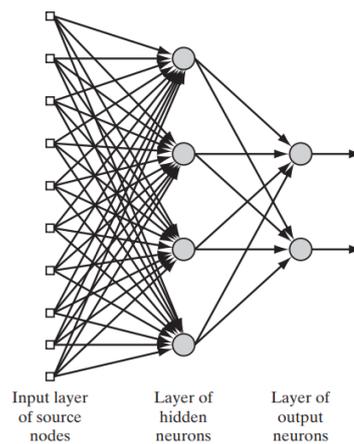
*Single layer* memiliki ciri khas yaitu lapis *input* langsung berhubungan dengan lapis *output* tanpa melalui *hidden layer*. Berikut merupakan struktur *single layer network* yang disajikan pada Gambar 2 (Haykin, 2009).



Gambar 2. Struktur *Single Layer Network*

b. *Multilayer Network*

*Multilayer network* merupakan jaringan yang memiliki tambahan satu *layer* tersembunyi diantara lapis *input* dan lapis *output* (Fausset, 1994). Jaringan yang memiliki banyak *layer* ini dapat memecahkan permasalahan yang lebih sulit dibandingkan dengan jaringan *single layer*. Berikut merupakan struktur *multilayer network* yang disajikan pada Gambar 3 (Haykin, 2009).



Gambar 3. Struktur *Multilayer Network*

### 2.3.2 Fungsi Aktivasi

Fungsi aktivasi ini mempunyai peranan yang sangat penting dalam suatu jaringan syaraf tiruan. Fungsi aktivasi berperan untuk menentukan keluaran suatu neuron. Fungsi aktivasi mempunyai karakteristik penting yaitu kontinu, terdiferensial dan monoton (Fausset, 1994). Ada beberapa fungsi aktivasi yang sering digunakan, yaitu :

#### 1. Fungsi Aktivasi *Rectified Linear Unit* (ReLU)

Fungsi aktivasi *ReLU* merupakan lapisan aktivasi pada model yang mengaplikasikan fungsi  $f(x) = \max(0, x)$ , dapat diartikan bahwa *ReLU* pada intinya hanya memuat pembatasan pada bilangan nol, artinya apabila  $x \leq 0$  maka  $x = 0$  dan apabila  $x > 0$  maka  $x = x$ . Kelebihan dari fungsi ini sangat mempercepat proses konvergensi yang dilakukan *Stochastic Gradient Descent* (SGD) apabila dibandingkan dengan fungsi *Sigmoid* dan *TanH* (Miranda & Castano, 2017).

#### 2. Fungsi Aktivasi *Linear*

Fungsi aktivasi *linear* merupakan fungsi yang memiliki nilai *output* yang sama dengan nilai *input*, dan dapat dirumuskan sebagai berikut :

$$\text{Linear Function ; } f(x) = x \quad (2.25)$$

Hal ini berkaitan dengan, jika sebuah *neuron* menggunakan fungsi aktivasi *linear* maka keluaran dari *neuron* tersebut adalah *weighted sum* dari *input* dijumlahkan dengan bias (Fausett, 1994)

### 2.3.3 Hyperparameter

Pemilihan parameter pada proses *hyperparameter* digunakan untuk mendapatkan hasil yang lebih baik. Parameter yang umum digunakan yaitu :

#### 1. Nodes pada *hidden layer*

Jumlah nodes pada *hidden layer* memegang peran penting dalam arsitektur jaringan syaraf tiruan. Penggunaan jumlah nodes yang terlalu sedikit dapat

mengakibatkan *underfitting*, sementara jumlah nodes yang terlalu banyak dapat membuat model terlalu kompleks dan menyebabkan *overfitting* (Kumar, 2015). Aturan-aturan yang umum digunakan dalam menentukan jumlah nodes pada *hidden layer* yang juga dikenal sebagai aturan heaton, yaitu :

1. Jumlah nodes pada *hidden layer* sebaiknya berada diantara jumlah nodes pada input dan output.
2. Jumlah nodes pada *hidden layer*  $2/3$  dari jumlah nodes pada *input* selanjutnya dijumlahkan dengan nodes pada *output*.
3. Jumlah nodes pada *hidden layer* sebaiknya kurang dari 2 kali jumlah nodes pada *input layer*.

## 2. *Epoch*

*Epoch* merupakan jumlah iterasi selama proses pelatihan yang memberikan *input* dari jaringan dan juga bobot jaringan diperbarui (Vijayalakshmi & Venkatachalapathy, 2019). Proses pelatihan tersebut diulang pada *neural network* dari awal lagi.

## 3. *Learning Rate*

*Learning rate* dapat digunakan untuk mengatur jumlah langkah yang diambil saat proses optimisasi atau penyesuaian bobot model selama pelatihan.

### 2.3.4 Algoritma *Backpropagation*

Algoritma *backpropagation* merupakan sebuah algoritma pembelajaran dalam metode ANN yang sudah banyak digunakan. Rumelhart dkk pada tahun 1986 memperkenalkan pertama kali ANN menggunakan algoritma *backpropagation*. Terdapat 3 fase utama dalam algoritma *backpropagation* (Fausett, 1994), yaitu :

#### 1. Propagasi maju (*feed forward*)

Tahap ini merupakan alur maju dari penggunaan ANN, dimana nilai *input* dihitung maju yang dikirimkan ke *hidden layer* dan kemudian dikirimkan ke *output layer* serta dihitung menggunakan fungsi aktivasi tertentu untuk mendapatkan nilai *output*.

2. Propagasi mundur (*backpropagation of error*)

Pada tahap ini dilakukan setelah *neural network* berhasil memberikan *output* dari perhitungan *input* pada tahap *feed forward*. Selama tahap ini, kesalahan yang terjadi diakibatkan karena terjadinya selisih keluaran dengan target yang diinginkan. Selanjutnya kesalahan yang didapatkan akan dipropagasikan mundur, dimulai dengan garis yang berhubungan langsung dengan unit-unit di *output layer*.

3. Perubahan nilai bobot (*adjustment*)

*Backpropagation* bekerja terlebih dahulu mencari error *output* dengan arah maju untuk mengoreksi bobot yang kemudian dilakukan dengan arah mundur. Perubahan bobot yaitu fase dimana dilakukannya modifikasi bobot untuk mengurangi kesalahan yang terjadi.

## 2.4 *Hybrid* GSTAR-ANN

Model *hybrid* merupakan suatu metode yang menggabungkan dua atau lebih model dalam satu sistem. Berikut ini merupakan alasan metode *hybrid* dikembangkan (Zhang, 2001), yaitu :

1. Sulit untuk menentukan apakah deret waktu mengandung pola linear ataupun nonlinear yang membuat peneliti menggunakan lebih dari satu metode untuk melakukan perbandingan dan mendapatkan hasil yang lebih akurat.
2. Permasalahan deret waktu yang murni linear ataupun nonlinear sangat jarang terjadi. Pola data biasanya memiliki keduanya. Apabila hal tersebut terjadi, maka metode tunggal dinilai kurang efektif karena tidak dapat menangkap pola campuran.
3. Tidak ada metode tunggal yang terbaik dalam situasi apapun. Hal ini didukung oleh fakta bahwa pola data yang kompleks dalam kasus nyata tidak dapat ditangani dengan baik menggunakan metode tunggal.

Secara umum kombinasi dari model deret waktu yang memiliki struktur autokorelasi linear dan nonlinear dapat dituliskan pada persamaan (2.26).

$$y_t = L_t + N_t \quad (2.26)$$

dengan :

- $y_t$  = nilai aktual ke- $t$ ,
- $L_t$  = komponen linear ke- $t$ ,
- $N_t$  = komponen nonlinear ke- $t$ ,
- $t$  = indeks waktu

Langkah pertama adalah menggunakan metode GSTAR untuk memodelkan komponen linear, kemudian residual dari model linear digunakan sebagai komponen nonlinear. Misalkan,  $e_t$  menunjukkan residual pada model linear saat  $t$  waktu, maka :

$$e_t = y_t - L'_t \quad (2.27)$$

dengan :

- $y_t$  = nilai aktual ke- $t$ ,
- $L'_t$  = nilai peramalan dari komponen linear ke- $t$ ,
- $e_t$  = nilai residual ke- $t$ ,
- $t$  = indeks waktu.

Residual sangat dibutuhkan dalam mendiagnosa model-model linear. Pemodelan residual menggunakan ANN dapat menemukan hubungan nonlinear pada data deret waktu. Sehingga pemodelan residual menggunakan ANN dengan  $n$  input dapat dituliskan pada persamaan (2.28).

$$e_t = f(e_{(t-1)}, e_{(t-2)}, \dots, e_{(t-n)}) + \varepsilon_t \quad (2.28)$$

dengan :

- $e_t$  = nilai residual ke- $t$ ,
- $f$  = fungsi nonlinear dari ANN,
- $\varepsilon_t$  = error,
- $t$  = indeks waktu

Sehingga, peramalan *hybrid* merupakan kombinasi dari dua komponen yang dapat dituliskan pada persamaan (2.29).

$$y'_t = L'_t + N'_t \quad (2.29)$$

dengan :

- $y'_t$  = nilai peramalan dari model *hybrid*,
- $L'_t$  = nilai peramalan dari komponen linear ANN,
- $N'_t$  = nilai peramalan dari komponen residual ANN,

## 2.5 Validasi Model

Untuk mengukur seberapa akurat hasil peramalan dibutuhkan suatu pengujian yang dapat mengetahui ukuran kesalahan peramalan dalam tingkat perbedaan antara hasil peramalan dengan data aktual. Metode yang dapat digunakan untuk mengukur akurasi peramalan adalah metode *Mean Square Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE).

Menurut Wei (2006), model peramalan dengan nilai MSE yang kecil maka semakin baik model yang digunakan. Perhitungan yang digunakan untuk memperoleh nilai MSE ditulis pada persamaan (2.30).

$$MSE = \frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2 \quad (2.30)$$

dengan :

- $n$  = jumlah data pengamatan,
- $Z_t$  = data pengamatan ke- $t$
- $\hat{Z}_t$  = nilai dugaan dari pengamatan ke- $t$

Nilai MAPE digunakan untuk mengetahui persentase penyimpangan hasil pendugaan. Perhitungan yang digunakan untuk memperoleh nilai MAPE ditulis pada persamaan (2.31).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100\% \quad (2.31)$$

dengan :

- $n$  = jumlah data pengamatan,
- $Z_t$  = data pengamatan ke- $t$
- $\hat{Z}_t$  = nilai dugaan dari pengamatan ke- $t$

Semakin kecil nilai MAPE maka dapat dikatakan semakin baik juga model peramalan yang digunakan. Kriteria nilai MAPE disajikan pada Tabel 1 (Chang, *et al.*, 2007).

Tabel 1. Kriteria Berdasarkan Nilai MAPE

MAPE	Kategori Peramalan
< 10%	Sangat Baik
10 – 20%	Baik
20 – 50%	Cukup
> 50%	Buruk

## 2.6 Perhitungan Nilai Bias

Bias merupakan istilah kuantitatif menjelaskan perbedaan antara rata-rata pengukuran yang dilakukan pada objek yang sama dengan nilai aslinya. Perhitungan yang digunakan untuk memperoleh nilai bias dapat ditulis pada persamaan (2.32).

$$Bias = \frac{\sum |\hat{y}_i - y_i|}{n} \quad (2.32)$$

dengan :

- $\hat{y}_i$  = data aktual,
- $y_i$  = data peramalan
- $n$  = periode waktu peramalan

## 2.7 Kelembaban Udara

Menurut BMKG (2006), kelembaban udara merupakan besarnya kadar uap air yang terkandung oleh udara. Kelembaban udara juga dapat dinyatakan sebagai Lembab Nisbi atau *Relatif Humidity*. Lembab Nisbi merupakan perbandingan antara massa uap air yang ada di dalam satu satuan volume dengan massa uap air yang diperlukan untuk menjenuhkan satu satuan udara tersebut pada suhu yang sama serta dinyatakan dalam bentuk persen.

### III. METODE PENELITIAN

#### 3.1 Waktu dan Tempat Penelitian

Penelitian dilakukan pada semester genap tahun ajaran 2023/2024 di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

#### 3.2 Data Penelitian

Data yang digunakan pada penelitian ini merupakan data sekunder, yaitu data bulanan kelembaban udara di tiga lokasi stasiun pengamatan yang berada di Provinsi Banten yakni Stasiun Klimatologi Tangerang Selatan, Stasiun Meteorologi Serang, dan Stasiun gGeofisika Tangerang dengan periode waktu dari bulan Januari 2016 hingga bulan April 2022. Pada penelitian ini menggunakan metode validasi silang untuk memastikan model yang diuji sesuai dengan data *ter-update* pada bulan Mei 2022 hingga bulan Desember 2022 yang diperoleh dari *website* Badan Pusat Statistik (BPS) Provinsi Banten yang dapat diakses pada link berikut <https://banten.bps.go.id/indicator/151/376/1/rata-rata-suhu-udara-menurut-bulan-dan-stasiun-pengamatan-di-provinsi-banten.html>

Adapun variabel yang digunakan pada penelitian ini adalah sebagai berikut :

$Z_1(t)$  = Kelembaban udara pada Stasiun Klimatologi Tangerang Selatan pada waktu ke- $t$

$Z_2(t)$  = Kelembaban udara pada Stasiun Meteorologi Serang pada waktu ke- $t$

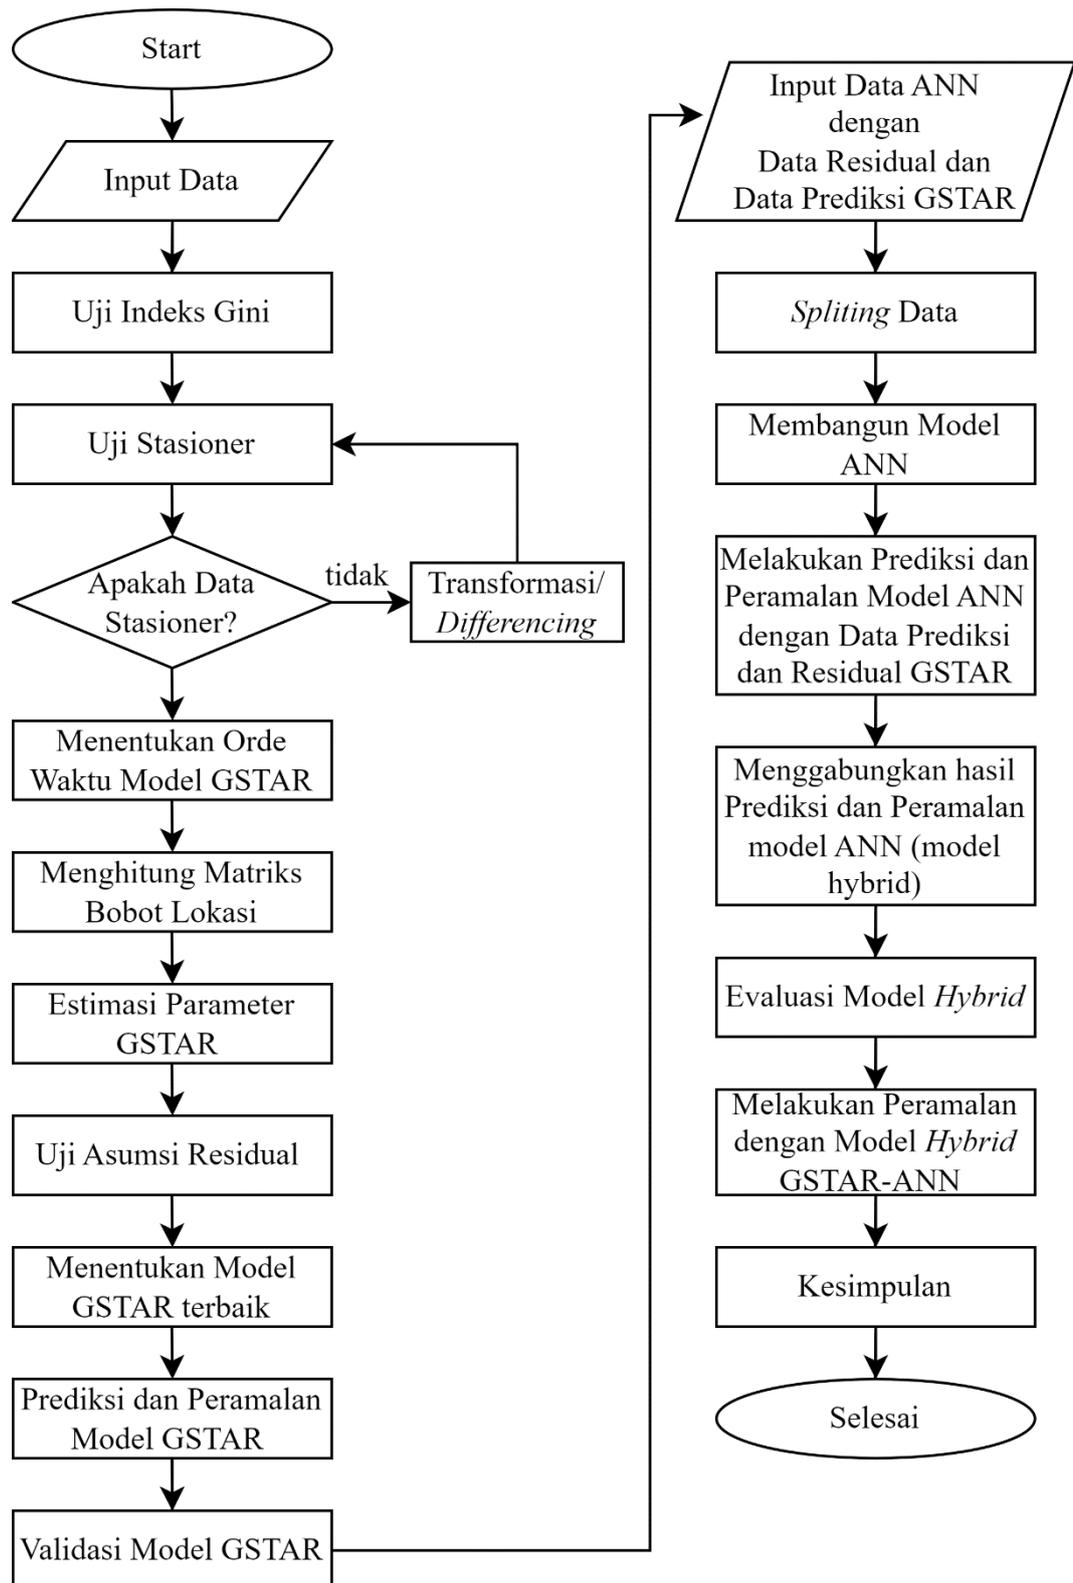
$Z_3(t)$  = Kelembaban udara pada Stasiun Geofisika Tangerang pada waktu ke- $t$

### 3.3 Metode Penelitian

Langkah-langkah yang akan dilakukan pada penelitian ini dengan menggunakan *software* RStudio dan Python adalah sebagai berikut :

1. Mendeskripsikan data nilai kelembaban udara untuk tiga lokasi.
2. Melakukan uji keheterogenan data dengan indeks Gini.
3. Melakukan uji kestasioneran data dengan menggunakan uji ADF.
4. Menentukan orde waktu dari model GSTAR yang sesuai berdasarkan hasil identifikasi pada model VAR dengan melihat nilai AIC terkecil.
5. Menghitung bobot lokasi menggunakan bobot invers jarak dan bobot normalisasi korelasi silang.
6. Menduga estimasi parameter menggunakan metode OLS.
7. Melakukan uji kesesuaian model dengan uji asumsi residual *white noise* dan uji normalitas multivariat.
8. Menentukan model GSTAR terbaik berdasarkan nilai MSE dan MAPE terkecil.
9. Melakukan prediksi dan peramalan model GSTAR menggunakan model terbaik GSTAR
10. Menghitung nilai residual dengan cara mengurangi data aktual dengan data hasil prediksi model GSTAR.
11. Data prediksi dan data residual dari model GSTAR digunakan sebagai input yang akan diolah dengan menggunakan metode ANN.
12. Melakukan *splitting* pada data prediksi dan data residual dari model GSTAR dengan skema 60% 40% yang merupakan 60% data *training* dan 40% data *testing*, skema 70% 30% yang merupakan 70% data *training* dan 30% data *testing* serta skema 80% 20% yang merupakan skema 80% data *training* dan 20% data *testing*.

13. Membuat dua model dengan menggunakan ANN sebagai landasan dalam melakukan proses *hybrid*. Model  $L'_t$  merupakan model yang digunakan untuk memprediksi data prediksi GSTAR. Model  $N'_t$  merupakan model yang digunakan untuk memprediksi data residual GSTAR.
14. Penentuan parameter terbaik untuk model ANN, dilakukan dengan menggunakan *hyperparameter tuning*.
15. Melakukan prediksi dan peramalan dengan model ANN  $L'_t$  menggunakan data prediksi GSTAR.
16. Melakukan prediksi dan peramalan dengan model ANN  $N'_t$  menggunakan data residual GSTAR.
17. Menggabungkan hasil prediksi dan peramalan dari kedua model dengan proses penjumlahan.
18. Hasil dari penggabungan kedua model merupakan model *hybrid* GSTAR-ANN.
19. Evaluasi model *hybrid* GSTAR-ANN.
20. Melakukan Peramalan menggunakan model *hybrid* GSTAR-ANN.



Gambar 4. Diagram Alur Pembentukan Model *Hybrid* GSTAR-ANN

## V. KESIMPULAN

Berdasarkan hasil analisis dan pembahasan diperoleh kesimpulan :

1. Model GSTAR yang terbaik yaitu model GSTAR ( $1_1$ ) dengan bobot lokasi yang digunakan ialah bobot lokasi normalisasi korelasi silang dan menghasilkan nilai MSE sebesar 9.807 dan nilai MAPE sebesar 0.554. Selanjutnya, model GSTAR dimodifikasi menggunakan model ANN. Model *hybrid* GSTAR-ANN skema 70% 30% memiliki nilai evaluasi yang lebih baik dibandingkan dengan skema 60% 40% dan skema 80% 20%. Model *hybrid* GSTAR-ANN skema 70% 30% menghasilkan nilai MSE sebesar 9.93 dan nilai MAPE sebesar 0.031.
2. Untuk hasil peramalan dengan menggunakan model *hybrid* GSTAR-ANN memiliki hasil yang lebih baik atau mendekati pola data *ter-update* (validasi silang) dibandingkan dengan model GSTAR yang dapat dilihat dari nilai biasanya.

## DAFTAR PUSTAKA

- Agustina, M.J., Surjanto, S.D., dan Apriliani, E. 2022. Estimasi Parameter Model Inflasi untuk Menganalisa Pengaruh Covid-19 Menggunakan GSTAR-Filter Kalman. *Jurnal Sains Dan Seni ITS*. **11**(2): 31-36.
- Amaly, M.H., Hirzi, R.H., dan Basirun. 2022. Perbandingan Metode ANN Backpropagation dan ARMA untuk Peramalan Inflasi di Internasional. *Jambura journal of probability and statistics*. **3**(2): 61-70.
- Aufa, S., Santoso, R., dan Suparti. 2022. Pemodelan Indeks Harga Properti Residensial di Internasional Menggunakan Metode Generalized Space Time Autoregressive. *Jurnal Gaussian*. **11**(1): 31-44.
- BMKG. 2006. Tata Cara Tetap Pelaksanaan Pengamatan Dan Pelaporan Data Iklim Dan Agroklimat. <https://jdih.bmkg.go.id/common/dokumen/Pengamatan%20dan%20Pelaporan%20Data%20Iklim%20dan%20Agroklimat.pdf>. Diakses pada 17 Januari 2024 pukul 16.45.
- Borovkova, S.A., Lopuhaa, H.P., dan Ruchjana, B.N. 2002. Generalized Star Model With Experimental Weights, hlm. 139-147. Proceedings of the 17<sup>th</sup> Internasional Workshop on Statistical Modelling, Chania.
- Box, G.E.P., Jenkins, G.M., Reinsel, G.C., dan Ljung, G.M. 1994. *Time Series Analysis Forecasting and Control*. 5<sup>th</sup> Edition. John Wiley & Sons, New Jersey.
- Chang, P.C., Wang, Y.W., dan Liu, C.H. 2007. The Development of a Weighted Evolving Fuzzy Neural Network for PCB Sales Forecasting. *Journal of Expert Systems with Applications*. **32**(1): 86-96.
- Cryer, J.D., dan Chan, K.S. 2008. *Time Series Analysis With Applications in R*. 2<sup>nd</sup> Edition. Springer, New York.

- Dana, I.M. 2018. Model Hybrid GSTARX-ANN Untuk Peramalan Data Space-Time Dengan Efek Variasi Kalender (Tesis). Departemen Statistika FMKSD ITS, Surabaya.
- Fausset, L.V. 1994. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice Hall, New Jersey.
- Hanke, J.E., dan Wichern, D.W. 2005. *Business Forecasting*. 9<sup>th</sup> Edition. Prentice Hall, Texas.
- Haykin, S. 2009. *Neural Networks and Learning Machines*. 3<sup>rd</sup> Edition. Pearson Education, New Jersey.
- Insany, G.P., Yustiana, I., dan Rahmawai, S. 2023. Penerapan KNN dan ANN pada Klasifikasi Status Gizi Balita Berdasarkan Indeks Antropometri. *Jurnal Computer Science and Information Technology*. 4(2): 385-393.
- Islamiyah, A.N., Rahayu, W., dan Wiraningsih, E.D. 2018. Pemodelan Generalized Space Time Autoregressive (GSTAR) dan Penerapannya pada Penderita TB PARu (BTA+) di DKI Internasional. *Jurnal Statistika dan Aplikasinya*. 2(2): 36-48.
- Khashei, M., dan Bijari, M. 2010. An Artificial Neural Network (p, d, q) Model for Time Series Forecasting. *Internasional Journal of Expert System with Applications*. 37(1): 479-489.
- Kumar, P. 2015. FF Neural Network. *IJRDO-Journal of Computer Science and Engineering*. 1(12): 44-58.
- Mansoer, A.S., Tarno, dan Wilandari, Y. 2016. Pemodelan Seasonal Generalized Space Time Autoregressive (SGSTAR). *Jurnal Gaussian*. 5(4): 593-602.
- Miranda, A., dan Castano, V. 2017. Smart Frost Control in Greenhouses by Neural Networks Models. *Computers and Electronics in Agriculture*. 137(1): 102-114.
- Montgomery, D C., Jennings, C.L., dan Kulachi, M. 2008. *Introduction to Time Series Analysis and Forecasting*. John Wiley & Sons, New Jersey.
- Nasrum, A. 2018. *Uji Normalitas Data Untuk Penelitian*. Jayapungus Press, Bali.

- Pfeifer, P.E., dan Deutsch, S.J. 1980. A Three-Stage Iterative Procedure for Space-Time Modeling. *Technometrics*. **22**(1): 35-47.
- Risnandar, A., dan Achmad, A.I. 2023. Pemodelan Generalized Space Time Autoregressive untuk meramalkan Indeks Harga Konsumen. *Jurnal Riset Statistika*. **3**(1): 43-50.
- Ruchjana, B.N. 2002. Pemodelan Kurva Produksi Minyak Bumi Menggunakan Model Generalisasi Star. *Forum Statistika dan Komputasi IPB, Bogor*.
- Siagian, H.A., Djuraidah, A., dan Sumertajaya, I. 2017. GSTAR and GSTAR-X Models to Forecast Inflation in Four Cities in North Sumatera. *Internasional Journal of Scientific & Engineering Research*. **8**(12): 1783-1787.
- Tsay, R.S. 2005. *Analysis of Internasional Time Series*. John Wiley & Sons, New Jersey.
- Vijayalakshmi, V., dan Venkatachalapathy, K. 2019. Deep Neural Network for Multi-Class Prediction of Student Performance in Educational Data. *Internasional Journal of Recent Technology and Engineering (IJRTE)*. **8**(12): 5073-5081.
- Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods*. 2<sup>nd</sup> Edition. Addison Wesley Publishing Company, USA.
- Wutsqa, D.U., Suhartono, dan Sutijo, B. 2010. Generalized Space-Time Autoregressive Modeling, hlm. 752-761. Proceedings of the 6<sup>th</sup> IMT-GT Conference on Mathematics, Statistics and its Applications (ICMSA), Universitas Tunku Abdul Rahman.
- Wutsqa, D.U., Suhartono, & Sutijo, B. 2012. Aplikasi Model Generalized Space Time Autoregressive pada Data Pencemaran Udara di Kota Surabaya. *Pythagoras*. **7**(2): 17-30.
- Zhang, G.P. 2001. Time Series Forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. **50**(17): 159-175.