

**APLIKASI METODE *HYBRID SINGULAR SPECTRUM*
ANALYSIS DAN *NEURAL NETWORK* PADA
PERAMALAN CURAH HUJAN KABUPATEN
PANGKAJENE DAN KEPULAUAN**

SKRIPSI



ALFIYAH SALSA DILA SABIR

H051191040

**DEPARTEMEN STATISTIKA PROGRAM STUDI STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM**

UNIVERSITAS HASANUDDIN

MAKASSAR

DESEMBER 2023

LEMBAR PERNYATAAN KEOTENTIKAN

Saya yang bertanda tangan di bawah ini menyatakan dengan sungguh-sungguh bahwa skripsi ini saya buat dengan judul:

Aplikasi Metode Singular Spectrum Analysis dan Neural Network pada Peramalan Curah Hujan Kabupaten Pangkajene dan Kepulauan

adalah benar hasil karya saya sendiri, bukan hasil plagiat dan belum pernah dipublikasikan dalam bentuk apapun

Makassar, 6 Desember 2023



Alfiyah Salsa Dila Sabir

NIM H051191040

**APLIKASI METODE *HYBRID SINGULAR SPECTRUM*
ANALYSIS DAN *NEURAL NETWORK* PADA
PERAMALAN CURAH HUJAN KABUPATEN
PANGKAJENE DAN KEPULAUAN**

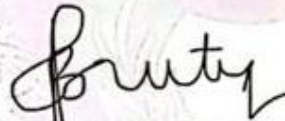
Disetujui Oleh:

Pembimbing Utama

Pembimbing Pertama



Sitti Sahriman, S.Si., M.Si.
NIP. 19881018 201504 2 002



Sri Astuti Thamrin, S.Si., M.Stat., Ph.D
NIP. 19740713 199903 2 001

Ketua Program Studi



Dr. Anna Islamiyati, S.Si., M.Si.
NIP. 19770808 200501 2 002

Pada 6 Desember 2023


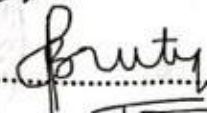

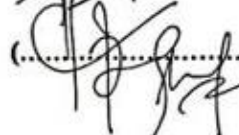
HALAMAN PENGESAHAN

Skripsi ini diajukan oleh:

Nama : Alfiyah Salsa Dila Sabir
NIM : H051191040
Program Studi : Statistika
Judul Skripsi : Aplikasi Metode *Hybrid Singular Spectrum Analysis* dan *Neural Network* pada Peramalan Curah Hujan Kabupaten Pangkajene dan Kepulauan

Telah berhasil dipertahankan dihadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Sarjana Sains pada Program Studi Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin.

DEWAN PENGUJI

1. Ketua : Sitti Sahrinan, S.Si., M.Si. (...)
2. Sekretaris : Sri Astuti Thamrin, S.Si., M.Stat., Ph.D (...)
3. Anggota : Drs. Raupong, M.Si. (...)
4. Anggota : Dr. Erna Tri Herdiani, S.Si., M.Si. (...)

Ditetapkan di : Makassar

Tanggal : 6 Desember 2023

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Puji syukur kehadiran Allah *Subhanahu Wa Ta'ala* atas segala limpahan rahmat, nikmat, dan hidayah-Nya yang telah diberikan sampai titik ini sehingga penulis mampu menyelesaikan penyusunan tugas akhir ini. Shalawat serta salam senantiasa tercurahkan kepada baginda Rasulullah *Shallallahu 'Alaihi Wa Sallam* beserta para keluarga, sahabat, dan pengikut beliau hingga akhir zaman kelak. *Alhamdulillah robbil'amin*, berkat nikmat kemudahan dan rahmat yang diberikan oleh Allah *Subhanahu Wa Ta'ala*, penulis dapat menyelesaikan tugas akhir yang berjudul “**Aplikasi Metode *Hybrid Singular Spectrum Analysis* dan *Neural Network* pada Peramalan Curah Hujan Kabupaten Pangkajene dan Kepulauan**” yang disusun sebagai salah satu syarat akademik memperoleh gelar sarjana pada Program Studi Statistika Departemen Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin.

Penulis menyadari bahwasannya dengan segala keterbatasan pengetahuan dan kemampuan yang dimiliki penyelesaian tugas akhir ini tidak terlepas dari dukungan dan dorongan dari berbagai pihak yang senantiasa turut memberikan bantuan baik secara moril maupun materil sehingga penulis dapat menyelesaikan tugas akhir ini. Oleh karena itu, penulis senantiasa mengucapkan terima kasih yang setulus-tulusnya serta penghargaan yang setinggi-tingginya untuk orang tua penulis, Ayahanda **Muhammad Sabir** dan Ibunda **Jahrawaty** yang telah membesarkan dan mendidik penulis, memberikan dukungan penuh, pengorbanan, kesabaran hati, limpahan cinta dan kasih sayang tanpa batas, pemenuhan materi dengan sangat cukup serta dengan ikhlas telah mengiringi setiap langkah penulis dengan doa dan restu mulianya. Ucapan terima kasih juga penulis haturkan kepada adik-adik tersayang penulis **Abrar Gailan Mubarak** dan **Arkan Fayyadh Mufid** karena telah menjadi adik-adik yang sangat baik dan senantiasa memberikan semangat maupun doa terbaiknya untuk penulis dalam menyelesaikan tugas akhir ini, serta keluarga besar penulis, terima kasih atas dukungan dan doa mulianya selama ini.

Penghargaan yang tulus dan ucapan terima kasih dengan penuh keikhlasan juga penulis ucapkan kepada:

1. **Bapak Prof. Dr. Ir. Jamaluddin Jompa, M.Sc.**, selaku Rektor Universitas Hasanuddin beserta seluruh jajarannya.
2. **Bapak Dr. Eng. Amiruddin**, selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin beserta seluruh jajarannya.
3. **Ibu Dr. Anna Islamiyati, S.Si., M.Si.**, selaku Ketua Departemen Statistika, segenap Dosen Pengajar dan Staf yang telah membekali ilmu dan kemudahan kepada penulis dalam berbagai hal selama menempuh Pendidikan sarjana di Departemen Statistika.
4. **Ibu Sitti Sahriman, S.Si., M.Si.**, selaku Pembimbing Utama yang dengan penuh kesabaran telah meluangkan waktu dan pemikirannya di tengah berbagai kesibukan dan prioritasnya untuk senantiasa memberikan arahan, dorongan semangat, dan motivasi kepada penulis mulai dari awal hingga selesainya penulisan skripsi ini.
5. **Ibu Sri Astuti Thamrin, S.Si., M.Stat., Ph.D**, selaku Pembimbing Pertama sekaligus Penasehat Akademik penulis yang senantiasa meluangkan waktu memberikan bantuan, nasehat, serta motivasi kepada penulis selama menjadi mahasiswa di Departemen Statistika.
6. **Bapak Drs Raupong, M.Si.** dan **Ibu Dr. Erna Tri Herdiani, S.Si., M.Si.**, selaku Tim Penguji yang telah meluangkan waktunya kepada penulis dengan senantiasa memberikan saran dan kritikan yang membangun kepada penulis dalam penyempurnaan tugas akhir ini.
7. Sahabat karib penulis sejak di bangku SD, **Finka Ayunita, A.Md.T.** yang senantiasa hadir sebagai penghibur di kala jenuh dengan skripsi dan menjadi tempat ternyaman untuk berkeluh kesah perihal apapun. Terima kasih telah tumbuh bersama dan masih menjadi teman terbaik dari kecil hingga dewasa ini.
8. Sahabat penulis di bangku SMP dan SMA, **Affah Aulia Ananda Arif, A.Md.T., A. Tenri Ola Batari Nuneng, Nur Khaliza, S.S**, serta keluarga besar **SMAN 13 Pangkep**. Terima kasih atas kebahagiaan, kebersamaan, kerukunan yang sampai saat ini masih penulis rasakan.
9. Keponakan *online*, **Rayyanza Malik Ahmad** yang selalu menebar kebahagiaan secara *online* dengan tingkah lucunya dan menjadi *moodboster* penulis selama penyusunan skripsi.

10. Seluruh teman-teman penulis di **Statistika 2019** yang tidak dapat disebutkan namanya satu per satu. Terima kasih untuk seluruh warna dalam pertemanan yang diberikan selama kurang lebih empat tahun lamanya.
11. Seluruh teman-teman **KKN PPM Pangkep Gelombang 108 Kecamatan Anrong Appaka**, yang bersedia menjadi keluarga selama kurang lebih dua bulan terkhusus kepada **Andi Annisa Hermansyah, Kintan Amara Dhiemma, dan Aurora Istijoany**, terima kasih karena menjadi orang yang paling meluangkan waktunya dan menjadi peluk paling hangat penulis selama di lokasi KKN.
12. Teman-teman **UKM Liga Film Mahasiswa Universitas Hasanuddin**, terima kasih untuk pengalaman tak ternilai yang diberikan kepada penulis selama di bangku perkuliahan pada beberapa projek produksi film.
13. Semua pihak yang terlibat dalam proses perkuliahan penulis yang tidak dapat penulis sebutkan satu per satu. Pastinya tak henti-henti penulis sampaikan semoga amal baik semua pihak mendapat balasan yang berlipat ganda dari sang pencipta yang pengasih dan penyayang Allah SWT. Amin.

Sebagai manusia biasa penulis menyadari penyusunan skripsi ini jauh dari kata sempurna karena keterbatasan kemampuan dan ilmu pengetahuan yang dimiliki oleh penulis. Oleh karenanya atas kesalahan dan kekurangan dalam penulisan skripsi ini, penulis memohon maaf dan bersedia menerima kritikan yang membangun.

Terakhir, harapan penulis, semoga skripsi ini dapat memberikan manfaat bagi siapa saja yang membacanya.

Makassar, 6 Desember 2023



Alfiyah Salsa Dila Sabir

**PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR UNTUK
KEPENTINGAN AKADEMIK**

Sebagai civitas akademik Universitas Hasanuddin, saya yang bertanda tangan di bawah ini:

Nama : Alfiyah Salsa Dila Sabir
NIM : H051191040
Program Studi : Statistika
Departemen : Statistika
Fakultas : Matematika dan Ilmu Pengetahuan Alam
Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Hasanuddin **Hak Bebas Royalti Non-eksklusif (*Non-exclusive Royalty-Free Right*)** atas tugas akhir saya yang berjudul:

“Aplikasi Metode *Singular Spectrum Analysis* dan *Neural Network* pada Peramalan Curah Hujan Kabupaten Pangkajene dan Kepulauan”

Beserta perangkat yang ada (jika diperlukan). Terkait dengan hal di atas, maka pihak universitas berhak menyimpan, mengalih-media/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat dan mempublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di Makassar tanggal 6 Desember 2023.

Yang menyatakan,



(Alfiyah Salsa Dila Sabir)

ABSTRAK

Kabupaten Pangkajene dan Kepulauan merupakan kabupaten di Sulawesi Selatan dengan curah hujan bulanan mencapai 200 mm hingga 560 mm/bulannya. Dampak dari intensitas curah hujan yang tinggi dapat menyebabkan berbagai efek negatif terhadap lingkungan seperti bencana banjir dan longsor. Akibat yang ditimbulkan dari bencana alam yang terlambat diantisipasi mengakibatkan biaya, tenaga, dan waktu yang dibutuhkan lebih besar. Penelitian ini bertujuan memperoleh hasil peramalan curah hujan yang nantinya dapat digunakan sebagai dasar-dasar perencanaan, pengawasan, dan pengambilan keputusan serta memberi informasi terkait besarnya intensitas curah hujan mendatang menggunakan metode *hybrid SSA-NN*. Metode SSA adalah metode yang mampu mendekomposisi suatu deret menjadi beberapa komponen, seperti komponen *trend*, musiman, dan *noise*, kemudian hasil dekomposisi pola-pola yang terbentuk oleh SSA selanjutnya digunakan untuk peramalan menggunakan metode NN. Hasil penelitian menunjukkan bahwa metode terbaik adalah gabungan metode SSA dengan *window length 23* dan metode NN dengan arsitektur model 6-4-1 (6 *neuron input* – 4 *neuron hidden* – 1 *neuron output*) untuk komponen *trend*, 6-3-1 (6 *neuron input* – 3 *neuron hidden* – 1 *neuron output*) untuk komponen musiman, serta 6-10-1 (6 *neuron input* – 10 *neuron hidden* – 1 *neuron output*) untuk komponen *noise*. Tingkat kesalahan prediksi berdasarkan nilai MAPE mencapai 7.24%. Dan dengan tingkat korelasi sebesar 0.946.

Kata Kunci: *Hybrid SSA-NN*, Peramalan, Curah Hujan

ABSTRACT

Pangkajene and Islands Regency is a district in South Sulawesi with monthly rainfall reaching 200 mm to 560 mm/month. The impact of high rainfall intensity can cause various negative effects on the environment such as floods and landslides. The consequences of natural disasters that are anticipated too late result in greater costs, energy and time required. This research aims to obtain rainfall forecasting results which can later be used as a basis for planning, monitoring and decision making as well as providing information regarding the magnitude of future rainfall intensity using the hybrid SSA-NN method. The SSA method is a method that can decompose a series into several components, such as trend, seasonal and noise components, then the results of the decomposition of the patterns formed by SSA are then used for forecasting using the NN method. The research results show that the best method is a combination of the SSA method with a window length of 23 and the NN method with a 6-4-1 model architecture (6 input neurons – 4 hidden neurons – 1 output neuron) for the trend component, 6-3-1 (6 input neurons – 3 hidden neurons – 1 output neuron) for the seasonal component, and 6-10-1 (6 input neurons – 10 hidden neurons – 1 output neuron) for the noise component. The prediction error rate based on the MAPE value reached 7.24%. And with a correlation level of 0.946.

Keywords: *Hybrid SSA-NN, Forecasting, Rainfall*

DAFTAR ISI

HALAMAN SAMPUL	i
HALAMAN SAMPUL	Error! Bookmark not defined.
LEMBAR PERNYATAAN KEOTENTIKAN	ii
HALAMAN PENGESAHAN	Error! Bookmark not defined.
KATA PENGANTAR	v
PERNYATAAN PERSETUJUAN	Error! Bookmark not defined.
ABSTRAK	viii
ABSTRACT	x
DAFTAR ISI	xi
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xiv
DAFTAR LAMPIRAN	xv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian.....	3
1.4 Batasan Masalah.....	3
1.5 Manfaat Penelitian.....	4
BAB II TINJAUAN PUSTAKA	5
2.1 <i>Singular Spectrum Analysis</i>	5
2.1.1 <i>Embedding</i>	5
2.1.2 <i>Singular Value Decomposition</i>	6
2.1.3 <i>Grouping</i>	6
2.1.4 <i>Diagonal Averaging</i>	7
2.2 <i>Neural Network</i>	8
2.2.1 Arsitektur Jaringan <i>Neural Network</i>	9
2.3 Algoritma <i>Backpropagation</i>	11
2.4 Fungsi Aktivasi.....	15
2.5 Pengukuran Akurasi	15
2.6 Curah Hujan	16
BAB III METODOLOGI PENELITIAN	18
3.1 Sumber Data	18
3.2 Struktur Data	18
3.3 Tahapan Analisis	18

BAB IV HASIL DAN PEMBAHASAN	22
4.1 Statistik Deskriptif Data	22
4.2 <i>Hybrid Singular Spectrum Analysis dan Neural Network</i>	23
4.2.1 <i>Singular Spectrum Analysis</i>	24
4.2.1.1 <i>Embedding</i>	24
4.2.1.2 <i>Singular Value Decomposition</i>	25
4.2.1.3 <i>Grouping</i>	27
4.2.1.4 <i>Diagonal Averaging</i>	29
4.2.2 <i>Neural Network</i>	30
4.2.2.1 <i>Feedforward</i>	33
4.2.2.2 <i>Backpropagation</i>	35
4.2.2.3 <i>Perubahan Bobot dan Bias</i>	37
4.3 <i>Prediksi Curah Hujan Kabupaten Pangkajene dan Kepulauan</i>	42
BAB V KESIMPULAN DAN SARAN	45
5.1 Kesimpulan.....	45
5.2 Saran	45
DAFTAR PUSTAKA	46
LAMPIRAN.....	51

DAFTAR GAMBAR

Gambar 2.1 Arsitektur Neural Network	9
Gambar 2.2 Jaringan Saraf Lapisan Tunggal	10
Gambar 2.3 Jaringan Saraf Lapisan Banyak	10
Gambar 2.4 Jaringan Saraf Lapisan Kompetitif	11
Gambar 4.1 Plot Deret Waktu Curah Hujan Kabupaten Pangkajene dan Kepulauan Pos Hujan Bungoro	22
Gambar 4.2 Grafik <i>Singular Value</i>	27
Gambar 4.3 Plot <i>Eigenvector</i>	28
Gambar 4.4 Plot Arsitektur <i>Neural Network</i> Komponen <i>Trend</i>	40
Gambar 4.5 Plot Arsitektur <i>Neural Network</i> Komponen Musiman	41
Gambar 4.6 Arsitektur <i>Neural Network</i> Komponen <i>Noise</i>	42
Gambar 4.7 Perbandingan Data Aktual dengan Hasil Prediksi SSA-NN	44

DAFTAR TABEL

Tabel 3.1 Struktur Data Penelitian	18
Tabel 4.1 Analisis Deskriptif Curah Hujan Kabupaten Pangkajene dan Kepulauan Pos Hujan Bungoro.....	23
Tabel 4.2 Hasil MAPE berdasarkan nilai L	24
Tabel 4.3 Hasil Tracking MAPE berdasarkan nilai L	24
Tabel 4.4 Eigenvalues dan Singular Values	26
Tabel 4.5 Eigenvector.....	26
Tabel 4.6 Principal Component.....	27
Tabel 4.7 Eigentriple dan Komponen yang Terkait	29
Tabel 4.8 Hasil Rekonstruksi	29
Tabel 4.9 Variabel Input dan Target.....	30
Tabel 4.10 Hasil MAPE berdasarkan Neuron	31
Tabel 4.11 Bobot Awal dan Bias Input Layer ke Hidden Layer pada Komponen Trend.....	32
Tabel 4.12 Bobot Awal dan Bias Hidden Layer ke Output Layer pada Komponen Trend.....	32
Tabel 4.13 Hasil Normalisasi	33
Tabel 4.14 Nilai Kesalahan Bobot	37
Tabel 4.15 Bobot Akhir dan Bias Input Layer ke Hidden Layer (1 kali iterasi)..	39
Tabel 4.16 Bobot Akhir dan Bias Hidden Layer ke Output Layer (1 kali iterasi)	39
Tabel 4.17 Hasil Prediksi dan Akurasi Hasil Prediksi	43
Tabel 4.18 Perbandingan MAPE dan Korelasi.....	43

DAFTAR LAMPIRAN

Lampiran 1. Data Curah Hujan Bulanan Kabupaten Pangkajene dan Kepulauan pada Pos Hujan Bungoro Periode 2018-2022.....	52
Lampiran 2. <i>Output</i> Hasil Rekonstruksi menggunakan <i>software R Studio</i>	53
Lampiran 3. <i>Output</i> Hasil Rekonstruksi menggunakan <i>software R Studio</i>	54
Lampiran 4. <i>Output</i> Bobot dan Bias Awal dengan Nilai <i>Random</i>	55
Lampiran 5. Data Hasil Normalisasi untuk <i>Input Neural Network</i>	56
Lampiran 6. Hasil Prediksi Metode <i>Hybrid SSA-NN</i> pada Data Uji.....	58
Lampiran 7. <i>Output</i> Perbandingan menggunakan MAPE dan Korelasi <i>Pearson</i>	59

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan negara beriklim tropis yang dilalui oleh garis khatulistiwa serta dikelilingi oleh dua benua dan dua samudra yang menjadikan Indonesia rentan terhadap perubahan iklim atau cuaca (Suryani dkk., 2018). Cuaca dan iklim memiliki hubungan yang saling mempengaruhi terhadap unsur-unsur yang lain seperti kelembapan udara, temperatur udara, dan curah hujan (Desvina dan Ratnawati, 2014). Curah hujan merupakan salah satu unsur yang memiliki pengaruh pada aktivitas kehidupan (Syaifullah, 2014). Badan meteorologi, klimatologi, dan geofisika (BMKG) mengelompokkan curah hujan bulanan menjadi empat kategori yaitu kategori rendah (0-100 mm), kategori sedang (100-300 mm), kategori tinggi (300-500 mm) dan kategori sangat tinggi (>500 mm) (Supriyati dkk., 2018).

Kabupaten Pangkajene dan Kepulauan merupakan salah satu kabupaten di Sulawesi Selatan dengan curah hujan bulanan 200 mm/bulannya namun dengan bulan terbasah mencapai lebih dari 560 mm/bulan (PangkepKab). Dampak dari curah hujan yang tergolong tinggi dapat menyebabkan bencana, seperti bencana banjir, longsor, dan efek negatif terhadap lingkungan. Bersumber dari detikSulsel (2023) banjir berhasil merendam 7 kecamatan di Kabupaten Pangkajene dan Kepulauan salah satunya adalah Kecamatan Bungoro, banjir terjadi akibat intensitas hujan yang cukup tinggi sejak pagi hingga tengah malam. Akibat yang ditimbulkan dari bencana alam yang terlambat diantisipasi akan mengakibatkan biaya, tenaga, dan waktu yang dibutuhkan lebih besar sehingga perlu dilakukan peramalan untuk memperkirakan besarnya curah hujan mendatang.

Analisis runtun waktu merupakan salah satu prosedur statistik yang umum digunakan untuk memodelkan kondisi curah hujan (Fauziah dkk., 2016). Peramalan data runtun waktu dapat dianalisis menggunakan metode yang beragam. Pemilihan metode bergantung pada berbagai aspek yang mempengaruhi seperti aspek waktu, pola data, tipe model sistem yang diamati, hingga tingkat keakuratan peramalan. Selain itu dalam menerapkan suatu metode, data harus memenuhi asumsi seperti stasioneritas dan normalitas (Christienova dkk., 2018). Saat ini telah berkembang metode non-linier yang dianggap mewakili kondisi data, karena terkadang

ditemukan data yang tidak memenuhi asumsi-asumsi pada model linier (Eksiandayani, 2016). Data curah hujan umumnya dapat dimodelkan secara linier namun pada saat sekarang karakteristik dan pola curah hujan terkadang sulit untuk diidentifikasi sehingga model linier tidak mampu menjelaskan karakteristik non-linier dari data dengan baik (Sinay dkk., 2020).

Beberapa pendekatan *non-linier* yang dapat digunakan dalam peramalan diantaranya, *support vector machine* (SVM), *long short-term memory* (LSTM), *k-nearest neighbors* (KNN) dan *singular spectrum analysis* (SSA). SSA merupakan salah satu pendekatan yang mempunyai tujuan utama yaitu mendekomposisikan deret waktu asli menjadi beberapa komponen yang dipisahkan seperti komponen *trend*, musiman, dan *noise* (Golyandina dkk., 2001). Berdasarkan tujuan tersebut, beberapa data deret waktu memerlukan dekomposisi agar pola diketahui secara terpisah. Golyandina dkk (2001) menjelaskan bahwa kurang optimalnya hasil dekomposisi dapat menjadi salah satu kekurangan SSA. Namun dalam prosesnya SSA dapat mengurangi *noise* atau unsur yang tidak relevan pada data, yang dapat memberikan nilai eror lebih kecil dan hasil yang stabil dalam peramalan.

Metode non-linier yang juga banyak digunakan dalam peramalan adalah *neural network* (NN) karena memiliki kemampuan untuk menangani data kompleks (Syamsiah dan Purwandani, 2019). NN dengan proses pembelajaran jaringan saraf, dianggap memiliki proses fungsi pendekatan khusus dan solusi terhadap masalah yang diberikan umumnya kurang akurat, sehingga kemampuan fungsi pendekatan dan ketepatan solusi perlu dipertimbangkan (Suryani dan Wahono, 2015). Namun metode NN memiliki kemampuan untuk mempelajari pola data yang diberikan pada tahap pelatihan dan juga memiliki toleransi kesalahan yang tinggi serta mampu menjalankan perhitungan secara paralel yang membuat proses menjadi singkat (Diwanda dkk., 2021). Oleh karena itu, untuk mendapatkan hasil ramalan yang lebih optimal dan akurat dilakukan *hybrid* antara metode *singular spectrum analysis* dan *neural network* yang menggabungkan kelebihan dari kedua metode. Secara umum juga telah disetujui dalam literatur peramalan bahwa belum terdapat satu metode yang mampu untuk di semua situasi (Eksiandayani, 2016).

Beberapa penelitian terdahulu dalam meramalkan curah hujan diantaranya Purnama (2022) mempelajari model peramalan curah hujan di Provinsi Gorontalo

dan melakukan peramalan untuk tahun 2022-2023 menggunakan metode *singular spectrum analysis*. Penelitian terkait lainnya dilakukan oleh Fitriyanti (2022) yang menggunakan *neural network* sebagai sistem prediksi dalam prakiraan curah hujan bulanan di Kabupaten Wajo, Sulawesi Selatan. Sementara Setyowati dkk (2019) telah melakukan penelitian menggunakan metode *hybrid singular spectrum analysis* dan *neural network* (SSA-NN) terkait peramalan *inflow* dan *outflow* mata uang Bank Indonesia.

Berdasarkan uraian tersebut, maka penelitian ini difokuskan dalam melakukan peramalan terkait data curah hujan di Kabupaten Pangkajene dan Kepulauan menggunakan metode *hybrid singular spectrum analysis* dan *neural network*. Pada penelitian ini menggunakan algoritma pembelajaran *neural network* yaitu *backpropagation* dengan fungsi aktivasi *sigmoid biner*. Hasil dari penelitian ini diharapkan mampu membantu sebagai dasar-dasar perencanaan, pengawasan, dan pengambilan keputusan serta memberi informasi terkait besarnya intensitas curah hujan bulanan kedepannya.

1.2 Rumusan Masalah

Berdasarkan uraian pada latar belakang, maka rumusan masalah pada penelitian ini adalah bagaimana hasil peramalan pada data curah hujan bulanan Kabupaten Pangkajene dan Kepulauan menggunakan metode *hybrid singular spectrum analysis* dan *neural network*?

1.3 Tujuan Penelitian

Berdasarkan perumusan masalah, penelitian ini bertujuan untuk memperoleh hasil peramalan pada data curah hujan bulanan Kabupaten Pangkajene dan Kepulauan menggunakan metode *hybrid singular spectrum analysis* dan *neural network*.

1.4 Batasan Masalah

Batasan masalah pada penelitian ini adalah sebagai berikut:

1. Data yang digunakan adalah data curah hujan bulanan periode 2018-2022.
2. Fungsi aktivasi dalam algoritma pembelajaran yang digunakan adalah *sigmoid biner*.

3. Pengujian kinerja peramalan menggunakan *mean absolute percentage error* (MAPE) dan korelasi.

1.5 Manfaat Penelitian

Manfaat yang diharapkan dari hasil penelitian ini adalah sebagai berikut:

1. Menambah wawasan dan pengetahuan mengenai peramalan dengan metode *hybrid singular spectrum analysis* dan *neural network*.
2. Memberikan inspirasi bagi pembaca dalam pengembangan metode dalam analisis runtun waktu.
3. Memberikan informasi kedepannya untuk kepentingan-kepentingan pihak yang terkait dengan keadaan hujan atau curah hujan di Kabupaten Pangkajene dan Kepulauan.

BAB II

TINJAUAN PUSTAKA

2.1 *Singular Spectrum Analysis*

Singular spectrum analysis (SSA) adalah teknik analisis deret waktu yang mendekomposisi deret waktu asli menjadi suatu penjumlahan dari sejumlah kecil komponen yang independen dan dapat diinterpretasikan seperti komponen *trend*, musiman, dan *noise*. Analisis deret waktu menjadi salah satu prosedur dalam statistika yang diterapkan untuk meramalkan peluang keadaan mendatang dalam rangka pengambilan keputusan. Dasar pemikiran deret waktu adalah pengamatan sekarang (Z_t) dipengaruhi oleh satu atau beberapa pengamatan sebelumnya (Z_{t-n}); $n = 1, 2, 3 \dots$. Berdasarkan dengan hal itu, maka model deret waktu dibuat karena secara statistik ada korelasi antar deret pengamatan (Adiputra dkk., 2021). SSA merupakan gabungan dari dua istilah *singular* dan *spectrum*. Istilah *singular* didefinisikan dekomposisi spektral atau dekomposisi eigen dari matriks lintasan dan istilah *spectrum* didefinisikan untuk penjumlahan satu set nilai eigen setelah dekomposisi spektral (Sakinah, 2018). SSA merupakan model yang terhindar dari banyaknya syarat seperti independensi dan normalitas residual. SSA mampu memodelkan data musiman dengan multi periode dan musiman kompleks (Chrisantama dkk., 2021).

Algoritma dasar SSA adalah membagi deret waktu ke dalam data deret waktu yang baru. Pada dasarnya SSA terdiri dari dua tahap, yaitu dekomposisi dan rekonstruksi. Tahap dekomposisi terdiri dari tahapan *embedding* dan *singular value decomposition* sedangkan tahap rekonstruksi terdiri dari tahapan *grouping* dan *diagonal averaging* (Khaeri dkk., 2018). Metode SSA terdiri dari 4 langkah yang terdiri dari 2 tahap yang saling melengkapi (Golyandina dkk., 2001), yaitu:

2.1.1 *Embedding*

Pada *embedding* mengubah data runtun waktu ke dalam bentuk matriks lintasan (*trajectory matrix*) dengan mentransformasikan data yang berdimensi satu (vektor) menjadi data multidimensional (matriks) (Siringoringo dkk., 2022). Data deret waktu awal diubah menjadi matriks *trajectory* yang memiliki dimensi $L \times K$, diketahui bahwa L merupakan *window length* yang menjadi baris matriks, sedangkan $K = N - L + 1$ yang menjadi kolom matriks (Satriani dkk., 2020).

Diasumsikan data deret waktu dengan panjang N , tanpa data hilang (*missing data*) dinyatakan dengan $X = \{x_1, x_2, \dots, x_n\}$, dan dengan rentang pemilihan nilai L adalah $2 < L < \frac{N}{2}$. Belum ada metode khusus untuk menentukan nilai L secara pasti, sehingga untuk menentukan nilai L dilakukan dengan proses coba-coba (*trial and error*) (Idrus dkk., 2022). Matriks *trajectory* dapat dituliskan sebagai berikut:

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_K \\ x_2 & x_3 & \cdots & x_{K+1} \\ \vdots & \cdots & \ddots & \vdots \\ x_L & x_{L+1} & \cdots & x_N \end{bmatrix} \quad (2.1)$$

2.1.2 Singular Value Decomposition

Singular value decomposition (SVD) atau dekomposisi nilai singular bertujuan untuk memperoleh pemisahan komponen dalam dekomposisi dari deret waktu untuk mempermudah pengolahan data (Satriani dkk., 2020). Misalkan matriks $S = XX^T$, dengan menggunakan matriks S kemudian dihitung *eigenvalue* $(\lambda_1, \lambda_2, \dots, \lambda_L)$ dengan urutan secara menurun $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$. Selain itu U_1, U_2, \dots, U_L adalah *eigenvector* dari masing-masing *eigenvalue* (Sitohang dan Darmawan, 2018). Rank dari matriks X dapat ditunjukkan dengan $d = \max\{i, \lambda_i \geq 0\}$. Jika dinotasikan $V_i = \frac{X^T U_i}{\sqrt{\lambda_i}}$ untuk $i = 1, 2, \dots, d$, maka SVD dari matriks lintasan adalah sebagai berikut (Idrus dkk., 2022):

$$X = X_1 + X_2 + \cdots + X_d \quad (2.2)$$

dengan $X_i = \sqrt{\lambda_i} U_i V_i^T$ memiliki rank 1 (Isnawati, 2018).

Matriks X terbentuk dari *eigenvector* U_i , *singular value* $\sqrt{\lambda_i}$ dan *principal component* V_i . Ketiga elemen pembentuk SVD ini disebut dengan *eigen-triple*. Konsep dasar SVD adalah mendapatkan barisan matriks dari matriks S yang pada masing-masing matriks dalam barisan tersebut mengandung *eigenvector* U_i , *singular value* $\sqrt{\lambda_i}$ dan *principal component* V_i yang menggambarkan karakteristik pada masing-masing matriks dalam barisan (Christienova dkk., 2018).

2.1.3 Grouping

Grouping adalah tahap penguraian matriks lintasan $L \times K$ menjadi beberapa komponen yaitu *trend*, musiman, dan *noise* yang terdapat pada data deret waktu

(Ningsih, 2021). Parameter yang digunakan pada tahap ini adalah *grouping effect* (r). *Grouping effect* digunakan untuk membatasi jumlah *eigentriple* yang akan mengidentifikasi komponen *trend* dan musiman. Pengelompokan berhubungan erat dengan pemecahan matriks X_i menjadi beberapa kelompok dan menjumlahkan matriks dalam masing-masing kelompok (Christienova dkk., 2018). Proses *grouping* dilakukan dengan cara mengelompokkan set-set indeks $i = \{1, 2, \dots, d\}$ menjadi m subset (Wicaksono dkk., 2019). Matriks X_i dipartisi ke m *disjoint subset* I_1, I_2, \dots, I_m . Jika $I = \{i_1, i_2, \dots, i_p\}$ maka yang dihasilkan dari matriks X_i sesuai dengan kelompok I yang didefinisikan sebagai $X_I = X_{i_1} + X_{i_2} + \dots + X_{i_p}$. Matriks yang dihasilkan dihitung untuk pengelompokan $I = I_1, I_2, \dots, I_m$ maka persamaan yang terbentuk sebagai berikut:

$$X_{I_x} = X_{I_1} + X_{I_2} + \dots + X_{I_m} \quad (2.3)$$

Prosedur pemilihan set I_1, I_2, \dots, I_m disebut *eigentriple grouping* (Shafira dkk., 2020).

2.1.4 Diagonal Averaging

Tahapan *diagonal averaging* adalah tahapan merekonstruksi masing-masing matriks yang terdapat pada matriks X_{I_x} menjadi data deret waktu yang baru dengan panjang N (Satriani dkk., 2020). Langkah dasar untuk melakukan tahap ini adalah mengubah bentuk dari matriks X_{I_x} dari tahap rekonstruksi menjadi matriks Hankel. Cara optimal untuk melakukannya adalah dengan mencari rata-rata semua elemen pada beberapa antidiagonal (Utami dkk., 2019). Dimisalkan matriks Y sebagai berikut:

$$Y = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1K} \\ y_{21} & y_{22} & \dots & y_{2K} \\ \vdots & \dots & \ddots & \vdots \\ y_{L1} & y_{L2} & \dots & y_{LK} \end{bmatrix} \quad (2.4)$$

Jika Y adalah matriks $L \times K$ dengan elemen $y_{ij}, 1 \leq i \leq L, 1 \leq j \leq K, L^* = \min(L, K), K^* = \max(L, K),$ dan $N = L + K - 1$. Rata-rata *diagonal averaging* diperoleh dengan rumus sebagai berikut (Asrof dkk., 2017):

$$g_k = \begin{cases} \frac{1}{k+1} \sum_{m=1}^{k+1} y_{m,k-m+2}^*; 0 \leq k < L^* - 1 \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m,k-m+2}^*; L^* - 1 \leq k < K^* \\ \frac{1}{N-k} \sum_{m=k-K^*+2}^{N-K^*+1} y_{m,k-m+2}^*; K^* \leq k < N \end{cases} \quad (2.5)$$

Berdasarkan persamaan (2.4) dan (2.5), misalnya dipilih $k = 1$ dihasilkan $g_1 = y_{11}$, $k = 2$ dihasilkan $g_2 = \frac{y_{12}+y_{21}}{2}$, dan seterusnya (Satriani dkk., 2020).


2.2 Neural Network

Jaringan saraf tiruan, dalam bahasa Inggris disebutkan *artificial neural network*, umumnya hanya disebut *neural network* (NN) merupakan sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan saraf biologi (Ma'rufah dkk., 2013). Kemampuan otak manusia seperti mengingat, menghitung, menggeneralisasi, dan adaptasi, diharapkan *neural network* dapat meniru kemampuan tersebut. NN berguna untuk memecahkan persoalan yang berkaitan dengan pengenalan pola, klasifikasi, prediksi dan data mining (Badrul, 2016). Jaringan saraf tiruan memiliki karakteristik sebagai berikut (Fausett, 1994):

1. Pola koneksi antara *neuron* yang disebut arsitektur.
2. Metode penentuan bobot pada koneksi (*training, learning, algoritma*).
3. Fungsi aktivasi yang dijalankan masing-masing *neuron* pada *input* jaringan untuk menentukan *output* (pembangkit sinyal).

Neural network terdiri atas elemen-elemen untuk pemrosesan informasi yang disebut dengan unit (*neuron, sel atau node*). Setiap *neuron* dihubungkan dengan *neuron* lainnya dengan suatu *connection link*, yang direpresentasikan dengan *weight/bobot*. Setiap *neuron* menggunakan fungsi aktivasi pada net *input* untuk menentukan prediksi *output*. *Neuron-neuron* dalam *neural network* disusun dalam grup, yang disebut *layer* (lapisan). Susunan *neuron-neuron* dalam lapis dan pola koneksi di dalam dan antar lapis disebut dengan arsitektur jaringan. Arsitektur jaringan ini merupakan salah satu karakteristik penting yang membedakan *neural network* (Kusumadewi, 2014). Secara umum lapisan pada arsitektur *neural network* terdapat tiga lapis yaitu *input layer, hidden layer, dan output layer*. Setiap lapisan

tersebut memiliki jumlah *neuron* yang berbeda-beda. Arsitektur *neural network* digambarkan seperti pada Gambar 2.1 sebagai berikut (Sholikhah, 2021):



Gambar 2.1 Arsitektur *Neural Network*

Berdasarkan Gambar 2.1 lapisan arsitektur *neural network* terdiri dari:


- a. *Input layer* yaitu lapisan dari beberapa *neuron* yang menerima sinyal dari luar kemudian diteruskan ke *neuron* lain yang ada pada jaringan yang menggambarkan suatu permasalahan. Banyak *node* atau *neuron* dalam lapis *input* tergantung banyaknya *input* dalam model dan setiap *input* menentukan satu *neuron* (Sonata, 2021).
- b. *Hidden layer* merupakan *node-node* yang ada di dalam lapisan tersembunyi. *Output* dari lapisan ini tidak secara langsung dapat diamati (Achmalia, 2019). *Hidden layer* terletak di antara lapis *input* dan lapis *output*, yang terdiri dari atas beberapa lapis tersembunyi (Sonata, 2021).
- c. *Output layer* merupakan lapisan yang menghasilkan solusi *neural network* terhadap suatu permasalahan. Setelah melalui proses *training*, *network* merespon *input* baru untuk menghasilkan *output* yang merupakan hasil peramalan (Kusumadewi, 2014).

2.2.1 Arsitektur Jaringan *Neural Network*

Di dalam jaringan saraf tiruan, *neuron-neuron* dikelompokkan dalam lapisan-lapisan (*layers*). Arsitektur jaringan NN dibagi menjadi 3 macam, yaitu sebagai berikut (Amalina, 2016):


1. Jaringan saraf dengan lapisan tunggal (*single layer net*), lapisan ini hanya terdapat satu lapisan dengan bobot yang terhubung. Dapat dikatakan ciri-ciri lapisan ini adalah memiliki satu lapisan *input* dan satu lapisan *output*. Lapisan

input sepenuhnya terkoneksi ke lapisan *output* tetapi tidak terkoneksi dengan unit yang berada pada lapisan yang sama. *Single layer* digambarkan pada Gambar 2.2 sebagai berikut (Sholikhah, 2021).



Gambar 2.2 Jaringan Saraf Lapisan Tunggal


- Jaringan saraf dengan banyak lapisan (*multi-layer net*), jaringan ini memiliki banyak lapisan dan satu atau lebih lapisan yang terletak di antara lapisan *input* dan lapisan *output*. Jaringan ini menyelesaikan permasalahan yang lebih rumit dibandingkan dengan lapisan tunggal. Terdapat sebuah lapisan dari bobot diantara dua tingkat yang berdekatan dari unit (*input*, *hidden* atau *output*). *Multi-layer* digambarkan pada Gambar 2.3 sebagai berikut (Sholikhah, 2021).



Gambar 2.3 Jaringan Saraf Lapisan Banyak

- Jaringan saraf dengan lapisan kompetitif (*competitive layer*), lapisan ini memiliki perbedaan dengan lapisan lain yang mana antar *neuron* saling dihubungkan. Jaringan ini disebut dengan *feedback loop* dikarenakan *output-*

nya ada yang memberikan informasi terhadap tiap *input*-nya. Jaringan ini memiliki satu perulangan (*loop*) umpan balik. *Competitive layer* digambarkan pada Gambar 2.4 sebagai berikut (Sholikhah, 2021).



Gambar 2.4 Jaringan Saraf Lapisan Kompetitif

2.3 Algoritma *Backpropagation*

Algoritma *backpropagation* pertama kali diperkenalkan pada tahun 1970-an, tetapi mulai berkembang secara luas pada tahun 1986 oleh David Rumelhart, Geoffrey Hinton, dan Ronald Williams. Pada perkembangannya *backpropagation* bekerja jauh lebih cepat daripada pendekatan lainnya, sehingga memungkinkannya digunakan untuk memecahkan masalah yang sebelumnya tidak dapat dipecahkan (Nielsen, 2015). *Backpropagation* merupakan sebuah algoritma pembelajaran dalam *artificial neural network* yang telah banyak digunakan untuk memecahkan kasus-kasus rumit. Di dalam algoritma ini dilakukan dua tahap perhitungan, yaitu perhitungan maju yang dilakukan untuk menghitung error antara *output* NN dengan target yang diinginkan. Dan yang berikutnya adalah perhitungan mundur yang menggunakan error yang telah didapatkan untuk memperbaiki bobot pada semua *neuron* yang ada (Ryandhi, 2017).

Tujuan algoritma *backpropagation* yang digunakan untuk menemukan fungsi yang bergerak secara berulang sehingga didapatkan fungsi maksimal atau minimal. *Backpropagation* banyak digunakan di beberapa aplikasi pengendalian karena proses *training*-nya didasarkan dengan interkoneksi yang sederhana, yaitu apabila *output* memberikan hasil yang salah maka bobot dikoreksi agar error dapat diperkecil dan tanggapan NN selanjutnya diharapkan mendekati nilai yang benar

sehingga menjadikan *backpropagation* juga berkemampuan untuk memperbaiki bobot pada *hidden layer* (Abhishek dkk., 2012).

Fausett (1994) menyatakan bahwa algoritma *backpropagation* dalam melakukan *training* terhadap suatu jaringan terdapat 3 tahapan yaitu fase *feedforward*, fase *backpropagation* dan fase perubahan atau penyesuaian bobot. Secara rinci langkah dalam algoritma *backpropagation* diuraikan sebagai berikut (Sholikhah, 2021):

1. Fase *feedforward* yaitu fase ketika setiap *input* dipropagasi (dihitung maju) menuju *hidden layer* hingga *output layer* dengan menggunakan fungsi aktivasi yang ditentukan.
 - a. Setiap unit pada *input layer* ($x_i, i = 1, 2, \dots, d$) menerima sinyal *input* x_i dan diteruskan ke *hidden layer*.
 - b. Jumlahkan tiap *hidden layer* ($Z_j, j = 1, 2, \dots, n$) dengan bobot sinyal *input*.

$$Z_{net_j} = v_{0j} + \sum_{i=1}^d x_i v_{ij} \quad (2.6)$$

dengan:

Z_{net_j} : nilai *output* untuk unit Z_j

x_i : nilai *input* ke- i

v_{ij} : bobot antara *input layer* ke- i dan *hidden layer* ke- j

v_{0j} : bias menuju *hidden layer* ke- j

Mengaplikasikan fungsi aktivasi untuk menghitung sinyal *output* dan kemudian mengirim sinyal ke semua unit pada *output layer*.

$$z_j = f(Z_{net_j}) = \frac{1}{1 + e^{-Z_{net_j}}} \quad (2.7)$$

dengan:

z_j : nilai aktivasi dari unit Z_j

- c. Setiap unit pada *output layer* ($Y_l, l = 1, 2, \dots, k$) menjumlahkan bobot sinyal *input*.

$$Y_{net_l} = w_{0k} + \sum_{j=1}^n z_j w_{jk} \quad (2.8)$$

dengan:

Y_{net_l} : nilai *output* untuk unit Y_l

w_{0k} : bias menuju *output layer* ke- k

w_{jk} : bobot antara *hidden layer* ke- j dan *output layer* ke- k

Mengaplikasikan fungsi aktivasinya untuk menghitung sinyal *output*.

$$y_l = f(Y_{net_l}) = \frac{1}{1 + e^{-Y_{net_l}}} \quad (2.9)$$

dengan:

y_l : nilai *output*

2. Fase *backpropagation* yaitu fase ketika kesalahan (selisih antara *output* dengan target yang diinginkan) yang terjadi dipropagasi mundur dari garis yang berhubungan langsung dengan unit-unit di *output layer*.

a. Setiap unit *output layer* ($Y_l, l = 1, 2, \dots, k$) menerima pola target sesuai dengan pola *training input*, dengan menghitung informasi error.

$$\delta_l = (t_l - y_l)f'(Y_{net_l}) \quad (2.10)$$

dengan:

δ_l : faktor koreksi error bobot w_{jk}

t_l : nilai target

Menghitung bobot barunya (digunakan untuk memperbaharui w_{jk}).

$$\Delta w_{jk} = \alpha \delta_l z_j \quad (2.11)$$

dengan:

Δw_{jk} : nilai koreksi error bobot w_{jk}

α : nilai *learning rate*

z_j : nilai aktivasi dari unit Z_j

Menghitung korelasi bias (digunakan untuk memperbaharui w_{0k}).

$$\Delta w_{0k} = \alpha \delta_l \quad (2.12)$$

dengan:

Δw_{0k} : nilai koreksi error bias

Mengirim ke unit *layer* sebelumnya.

b. Setiap *hidden* ($Z_j, j = 1, 2, \dots, n$) menjumlahkan delta *input*.

$$\delta_{net_l} = \sum_{l=1}^k \delta_l w_{jk} \quad (2.13)$$

dengan:

δ_{net_l} : nilai untuk menghitung kesalahan *hidden layer*

w_{jk} : bobot antara *hidden layer* ke- j dan *output layer* ke- k

Turunan dari fungsi aktivasi dikalikan dengan nilai kesalahan pada *hidden layer* untuk menghitung informasi error

$$\delta_l = \delta_{net_l} f'(Z_{net_j}) = \delta_{net_l} z_j (1 - z_j) \quad (2.14)$$

dengan:

δ_l : faktor koreksi error bobot v_{ij}

Menghitung koreksi bobot (digunakan untuk memperbaharui v_{ij}).

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (2.15)$$

dengan:

Δv_{ij} : nilai koreksi error bobot v_{ij}

x_i : nilai *input* ke- i

Menghitung koreksi bias (digunakan untuk memperbaharui v_{0j}).

$$\Delta v_{0j} = \alpha \delta_j \quad (2.16)$$

dengan:

Δv_{0j} : nilai koreksi error bias

3. Fase perubahan bobot dan bias yaitu fase dilakukannya modifikasi bobot untuk menurunkan kesalahan yang terjadi.

Setiap unit *output* Y_l memperbaharui bias dan bobot ($l = 1, 2, \dots, k$)

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (2.17)$$

$$w_{0k}(\text{baru}) = w_{0k}(\text{lama}) + \Delta w_{0k} \quad (2.18)$$

Setiap *hidden* unit Z_j memperbaharui bobot dan bias ($j = 1, 2, \dots, n$)

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (2.19)$$

$$v_{0j}(\text{baru}) = v_{0j}(\text{lama}) + \Delta v_{0j} \quad (2.20)$$

2.4 Fungsi Aktivasi

Fungsi aktivasi adalah *output* yang didapatkan pada sebuah *neuron* dengan menggunakan langkah aktivasi tertentu berdasarkan *output* dari penggabungan *linier* (Saraswati dkk., 2021). Dalam jaringan saraf tiruan, fungsi aktivasi dipakai untuk menentukan keluaran suatu *neuron* (Rahayu dkk., 2018). Fungsi aktivasi ini memiliki peranan sangat penting dalam suatu jaringan yang penggunaannya sesuai kebutuhan dan target yang diinginkan. Fungsi aktivasi ini menentukan besarnya bobot (Sholikhah, 2021).

Fungsi aktivasi *sigmoid biner* biasanya digunakan dalam NN untuk pelatihan data dengan metode *backpropagation*. Fungsi aktivasi *sigmoid biner* memiliki *range* dari 0 hingga 1. Namun, fungsi ini bisa juga digunakan oleh NN yang nilai *output*-nya 0 atau 1. Rumus fungsi aktivasi *sigmoid biner* sebagai berikut (Achmalia, 2019):

$$y = f(x) = \frac{1}{1 + e^{-x}} \quad (2.21)$$

dengan $f'(x) = f(x)[1 - f(x)]$.

2.5 Pengukuran Akurasi

Metode prediksi dibutuhkan tingkat akurasi yang tinggi, maka untuk mengetahuinya diperlukan menghitung tingkat kesalahan dalam prediksi. Semakin kecil tingkat kesalahan yang dihasilkan dari hasil prediksi maka semakin baik prediksi (Sinaga dan Irawati, 2018). Metode atau teknik yang digunakan untuk melakukan evaluasi atau validasi adalah *mean absolute percentage error* (MAPE) dan korelasi *pearson*. MAPE merupakan metode yang menghitung kesalahan (*residu*) menggunakan kesalahan pada tiap periode dibagi dengan nilai observasi untuk periode itu. Kemudian, dihitung rata-rat (*mean*) dari kesalahan persentase tersebut (Ryandhi, 2017). MAPE dapat dihitung dengan rumus berikut:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{x_t - \hat{x}_t}{x_t} \right|}{n} \times 100\% \quad (2.22)$$

Korelasi *pearson* merupakan salah satu pengujian korelasi yang bertujuan untuk mengetahui seberapa erat hubungan dari dua variabel. Nilai positif adalah nilai 1, nilai -1 merupakan nilai negatif, dan 0 merupakan nilai yang tidak terdapat korelasi.

Apabila terdapat nilai korelasi yang mendekati satu maka korelasi antara dua variabel akan semakin kuat. Namun sebaliknya apabila nilai korelasi mendekati nol maka korelasi antara dua variabel lemah (Windarto, 2020). Korelasi *pearson* dapat dihitung dengan rumus berikut

$$r = \frac{\frac{1}{n} \sum_{t=1}^n (x_t - \bar{x})(\hat{x}_t - \bar{\hat{x}})}{\left[\left(\frac{1}{n} \sum_{t=1}^n (x_t - \bar{x})^2 \right) \left(\frac{1}{n} \sum_{t=1}^n (\hat{x}_t - \bar{\hat{x}})^2 \right) \right]^{\frac{1}{2}}} \quad (2.23)$$

dengan:

- \hat{x}_t : nilai prediksi ke- t
- x_t : nilai aktual ke- t
- n : banyaknya data

2.6 Curah Hujan

Hujan merupakan gejala meteorologi dan unsur klimatologi. Hujan yang sampai ke permukaan tanah dapat diukur dengan mengukur tinggi hujan tersebut berdasarkan volume air hujan per satuan luas. Hasil pengukuran tersebut dinamakan curah hujan (Habinuddin dkk., 2019). Curah hujan merupakan endapan berupa cairan yang jatuh ke permukaan bumi dengan variabilitas yang besar dalam ruang dan waktu. Berdasarkan skala ruang, variabilitasnya sangat dipengaruhi oleh letak geografi, topografi, ketinggian tempat, arah angin umum, dan letak lintang (Faulina, 2014). Curah hujan biasanya disajikan dalam satuan milimeter (mm). Rata-rata curah hujan di Indonesia cukup tinggi karena wilayahnya yang terletak di daerah tropis dan dikelilingi lautan luas (Utami dkk., 2021).

Atmosfer di atas wilayah Indonesia memainkan peranan penting dan unik dalam dinamika atmosfer global. Pada wilayah Indonesia 70% adalah perairan, maka jumlah uap air yang dapat diendapkan sangat besar, sehingga pembentukan awannya unik dan jumlah curah hujannya berfluktuasi dari bulan ke bulan, dari musim ke musim, atau dari tahun ke tahun. Kerumitan dinamika atmosfer ekuator dan keunikan atmosfer benua maritim menyebabkan kesulitan untuk melakukan prediksi cuaca dengan tingkat ketelitian yang tinggi (Tjasyono, 2009).

Pengamatan terhadap curah hujan umumnya dilakukan secara konvensional. Pengamatan dilakukan dengan menakar jumlah curah hujan yang jatuh di

permukaan bumi menggunakan alat penakar hujan. Untuk mendapatkan curah hujan, maka diperlukan stasiun pengamatan cuaca/iklim sebagai tempat observasi di darat (Swarinoto dan Husain, 2012). Curah hujan dapat diukur dengan alat pengukur curah hujan otomatis atau yang manual. Alat-alat pengukur tersebut harus diletakkan pada daerah yang masih alamiah, sehingga curah hujan yang terukur dapat mewakili wilayah yang luas. Salah satu tipe pengukur hujan manual yang banyak dipakai adalah tipe observatorium (obs) atau biasa disebut ombrometer. Curah hujan dari pengukuran alat ini dihitung dari volume air hujan per luas mulut penakar. Alat tipe observatorium ini merupakan alat baku dengan mulut penakar seluas 100 cm^2 dan dipasang dengan ketinggian mulut penakar 1.2 meter dari permukaan tanah (Aini, 2017).