

**IMPLEMENTASI METODE *BACKPROPAGATION ARTIFICIAL
NEURAL NETWORK* DAN ALGORITMA GENETIKA
TERHADAP ESTIMASI PENDAPATAN AGEN EKSPEDISI
PENGIRIMAN BARANG**

SKRIPSI

Diajukan untuk Memenuhi Sebagai Syarat Guna
Memperoleh Gelar Sarjana Matematika
Dalam Ilmu Matematika



Diajukan oleh:
ACHMAD YUSUF NAUFAL
NIM. 1808046014

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI WALISONGO
SEMARANG
2022**

PERNYATAAN KEASLIAN

Yang bertandatangan di bawah ini:

Nama : Achmad Yusuf Naufal

NIM : 1808046014

Program Studi : Matematika

Menyatakan bahwa skripsi yang berjudul:

Implementasi Metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika Terhadap Estimasi Pendapatan Agen Ekspedisi Pengiriman Barang

Secara keseluruhan adalah hasil penelitian/karya saya sendiri, kecuali bagian tertentu yang dirujuk sumbernya.

Semarang, 29 November 2022

Pembuat



Achmad Yusuf Naufal

NIM. 1808046014

PENGESAHAN



KEMENTERIAN AGAMA REPUBLIK INDONESIA
UNIVERSITAS ISLAM NEGERI WALISONGO SEMARANG
FAKULTAS SAINS DAN TEKNOLOGI
Alamat: Jl Prof. Dr. Hamka Km. 1 Semarang Telp. 024 76433366 Semarang 50185
E-mail: fst@walisongo.ac.id, Web : <http://fst.walisongo.ac.id>

PENGESAHAN

Naskah skripsi berikut ini:

Judul : IMPLEMENTASI METODE *BACKPROPAGATION ARTIFICIAL NEURAL NETWORK* DAN ALGORITMA GENETIKA TERHADAP ESTIMASI PENDAPATAN AGEN EKSPEDISI PENGIRIMAN BARANG
Nama : Achmad Yusuf Naufal
NIM : 1808046014
Jurusan : Matematika

Telah diujikan dalam ujian tugas akhir oleh Dewan Penguji Fakultas Sains dan Teknologi dan dapat diterima sebagai salah satu syarat memperoleh gelar sarjana dalam ilmu Matematika.

Semarang, 12 Desember 2022

DEWAN PENGUJI

Ketua Sidang / Penguji,  Mohamad Tafrikan, M.Si. NIP. 19890417 201903 1 010	Sekretaris Sidang / Penguji,  Ariska Kurnia Rachmawati, M.Sc. NIP. 19890811 201903 2 019
Penguji Utama I,  Emy Siswanah, M.Sc. NIP.19870202 201101 2 014	Penguji Utama II,  Softina Diyah Miasary, M.Sc. NIP. 19870921 201903 2 010
Pembimbing I,  Mohamad Tafrikan, M.Si. NIP. 19890417 201903 1 010	Pembimbing II,  Ariska Kurnia Rachmawati, M.Sc. NIP. 19890811 201903 2 019

NOTA DINAS

Semarang, 29 November 2022

Yth. Ketua Program Studi Matematika

Fakultas Sains dan Teknologi

UIN Walisongo Semarang

Assalamu'alaikum Warahmatullahi Wabarakatuh

Dengan ini diberitahukan bahwa saya telah melakukan bimbingan, arahan, dan koreksi naskah skripsi dengan:

Judul : Implementasi Metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika Terhadap Estimasi Pendapatan Agen Ekspedisi Pengiriman Barang

Nama : Achmad Yusuf Naufal

NIM : 1808046014

Program Studi : Matematika

Saya menandakan bahwa naskah skripsi tersebut sudah dapat diajukan kepada Fakultas Sains dan Teknologi UIN Walisongo Semarang untuk diajukan dalam Sidang Munaqasyah.

Wassalamu'alaikum Warahmatullahi Wabarakatuh

Pembimbing I,



Mohamad Tafrikan, M.Si.

NIP.19890417 201903 1 010

NOTA DINAS

Semarang, 29 November 2022

Yth. Ketua Program Studi Matematika

Fakultas Sains dan Teknologi

UIN Walisongo Semarang

Assalamu'alaikum Warahmatullahi Wabarakatuh

Dengan ini diberitahukan bahwa saya telah melakukan bimbingan, arahan, dan koreksi naskah skripsi dengan:

Judul : Implementasi Metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika Terhadap Estimasi Pendapatan Agen Ekspedisi Pengiriman Barang

Nama : Achmad Yusuf Naufal

NIM : 1808046014

Program Studi : Matematika

Saya menandakan bahwa naskah skripsi tersebut sudah dapat diajukan kepada Fakultas Sains dan Teknologi UIN Walisongo Semarang untuk diajukan dalam Sidang Munaqasyah.

Wassalamu'alaikum Warahmatullahi Wabarakatuh

Pembimbing II,



Ariska Kurnia Rachmawati, M.Sc.

NIP. 19890811 201903 2 019

TRANSLITERASI ARAB-LATIN

Penulisan transliterasi huruf-huruf Arab Latin dalam skripsi ini berpedoman pada (SKB) Menteri Agama dan Menteri Pendidikan dan Kebudayaan R.I

Konsonan

Nomor: 158 Tahun 1987 dan Nomor: 0543b/U/1987.

Daftar huruf bahasa Arab dan transliterasinya ke dalam huruf Latin dapat dilihat pada halaman berikut:

Huruf Arab	Nama	Huruf Latin	Nama
ا	Alif	Tidak Dilambangkan	Tidak Dilambangkan
ب	Ba	B	Be
ت	Ta	T	Te
ث	Ṣa	Ṣ	Es (dengan titik di atas)
ج	Jim	J	Je
ح	Ḥa	Ḥ	Ha (dengan titik di atas)
خ	Kha	Kh	Ka dan Ha
د	Dal	D	De

ذ	Zal	Z	Zet (dengan titik di atas)
ر	Ra	R	Er
ز	Zai	Z	Zet
ش	Sin	S	Es
ش	Syin	Sy	Es dan Ye
ص	Ṣad	Ṣ	Es (dengan titik di bawah)
ض	Ḍad	Ḍ	De (dengan titik di bawah)
ط	Ṭa	Ṭ	Te (dengan titik di bawah)
ظ	Ẓa	Ẓ	Zet (dengan titik di bawah)
ع	Ain	–	Apostrof terbalik
غ	Gain	G	Ge
ف	Fa	F	Ef
ق	Qof	Q	Qi
ك	Kaf	K	Ka
ل	Lam	L	El
م	Mim	M	Em
ن	Nun	N	Ea
و	Wau	W	We

هـ	Ha	H	Ha (dengan titik di atas)
ء	Hamzah	ـ'	Apostrof
ي	Ya	Y	Ye

Judul : IMPLEMENTASI METODE
**BACKPROPAGATION ARTIFICIAL NEURAL
NETWORK DAN ALGORITMA GENETIKA
TERHADAP ESTIMASI PENDAPATAN
AGEN EKSPEDISI PENGIRIMAN BARANG**

Penulis : Achmad Yusuf Naufal
NIM : 1808046014

ABSTRAK

Pendapatan merupakan jumlah penghasilan yang diterima oleh seseorang atau penduduk atas prestasi kerjanya selama satu periode tertentu, baik harian, mingguan, bulanan ataupun tahunan. Penelitian ini mengimplementasikan metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika untuk mengestimasi pendapatan agen JNE Express Sekaran. ANN dan Algoritma Genetika merupakan metode peramalan modern yang menghasilkan nilai error terkecil dan akurat. Berdasarkan penelitian yang telah dilakukan, metode *Backpropagation Artificial Neural Network* menghasilkan model arsitektur terbaiknya, yaitu 4-10-1 dengan 4 sebagai *input layer*, 10 sebagai *hidden neuron*, dan 1 sebagai *output layer*. Dengan *epoch* 487 menghasilkan MSE 0.150807. Sedangkan metode Algoritma Genetika menghasilkan nilai *fitness* terbaiknya, yaitu 10209.02 dengan ukuran populasi 200, probabilitas pindahsilang 0.8, probabilitas mutasi 0.03 pada generasi ke-498 dan memperoleh nilai MSE 0.000098. Sehingga, dapat diprediksi pendapatan untuk bulan berikutnya, yaitu bulan Oktober 2021 sebesar Rp 25,011,603.00, bulan November 2021 sebesar Rp 20,920,021.00, dan bulan Desember 2021 sebesar Rp 50,553,019.00

Kata Kunci : Pendapatan, Peramalan, *Backpropagation Artificial Neural Network*, Algoritma Genetika.

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh

Puji syukur atas segala rahmat, karunia dan kemudahan yang diberikan Allah Subhanahu Wa Ta'ala sehingga penulis dapat menyelesaikan penyusunan skripsi ini dengan baik dan lancar. Shalawat serta salam semoga senantiasa tercurah kepada Rasulullah Shallallahu 'Alaihi Wa Sallam yang selalu dinantikan syafaatnya kelak di hari akhir nanti.

Penyusunan skripsi ini bertujuan guna memenuhi tugas dan persyaratan untuk memperoleh gelar sarjana dalam Ilmu Matematika Fakultas Sains dan Teknologi UIN Walisongo Semarang. Penyusunan skripsi ini tidak lepas dari bantuan, dukungan, motivasi, dan doa dari berbagai pihak. Pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Dekan Fakultas Sains dan Teknologi UIN Walisongo Semarang Dr. H. Ismail, M. Ag.
2. Ketua Program Studi Matematika UIN Walisongo Semarang Emy Siswanah, M.Sc.
3. Dosen pembimbing dalam proses penyusunan skripsi Mohamad Tafrikan, M.Si. dan Ariska Kurnia Rachmawati, M.Sc. yang telah melimpahkan kasih

sayang, kesabaran dalam memberikan bimbingan, arahan, selama proses penulisan hingga terselesaikannya skripsi ini dengan baik.

4. Dosen wali Ahmad Aunur Rohman, M.Pd. yang telah memberikan arahan, bimbingan, dan semangat selama proses perkuliahan.
5. Segenap Bapak dan Ibu dosen Fakultas Sains dan Teknologi UIN Walisongo Semarang yang telah memberikan bekal pengetahuan selama proses perkuliahan.
6. Kepada Ibu Nasroka, Eka Marta Tristiawan sekeluarga, Okky Prasetyo sekeluarga yang telah memberikan semangat, motivasi, dukungan, doa, dan kebaikan lainnya sehingga penulis dapat menyelesaikan penyusunan skripsi. Tak lupa skripsi ini saya berikan kepada Bapak Sutrisman Rahimahullahu, semoga beliau bangga atas anaknya yang telah menyelesaikan skripsi ini. Semoga amal dan ibadah beliau diterima disisi Allah, Aamiin.
7. Teman spesial Silva Aprilia Salsabela yang selalu memberikan semangat, dukungan, doa, motivasi, kebaikan, dan waktu kepada saya sehingga dapat menyelesaikan skripsi ini dengan baik.

8. Ibu Ambariyah dan Bapak Samsul Bahri yang telah memberikan dukungan, semangat, kehangatan, kekeluargaan, dan kebersamaan.
9. Segenap teman-teman Matematika angkatan 2018 yang telah berjuang, belajar, saling support dan berbagi rasa yang sama selama di bangku perkuliahan.
10. Segenap keluarga besar UKM Saintek Sport Fakultas Sains dan Teknologi UIN Walisongo dari keluarga yang telah mengajarkan bagaimana menjadi seorang pemimpin, aktivis dan mengajarkan bagaimana cara memanajemen sebuah organisasi dan waktu.
11. Kepada teman-teman Kuliah Kerja Nyata (KKN) Mandiri Inisiatif Terprogram (MIT) Ke-13 Kelompok 11 tahun 2022 Desa Sumberahayu, Kecamatan Limbangan, Kabupaten Kendal yang telah memberikan pengalaman, dan warna kehidupan yang berarti bagi penulis.
12. Segenap teman-teman Squad SHS yang telah memberikan pengalaman, berbagi informasi, saling support, dan memberikan warna kehidupan yang berarti bagi penulis.
13. Kepada sahabat-sahabat saya Alya Namira Ikfinasulkha, Santhi Muhaimina Azma, Roy Rolanda,

Syuja Zhafran, Zulyas Eko Wicaksono, Dheva Yustisio yang telah memberikan dukungan, motivasi, semangat dan menjadi tempat curhat, teman kabar.

14. Kepada semua pihak yang telah memberikan dukungan dan semangat yang tidak dapat penulis sebutkan satu per satu.

Penulis tidak dapat memberikan balasan apapun selain ucapan terima kasih dan doa, semoga Allah senantiasa membalas semua kebaikan mereka dengan sebaik-baiknya balasan. Penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna. Oleh karena itu, saran perbaikan yang membangun sangat diharapkan demi kesempurnaan skripsi ini dan semoga dapat bermanfaat bagi semua pihak.

Wassalamu'alaikum Warahmatullahi Wabarakatuh

Semarang, 29 November 2022



Achmad Yusuf Naufal

1808046014

DAFTAR ISI

PERNYATAAN KEASLIAN.....	i
PENGESAHAN	ii
NOTA DINAS.....	iii
NOTA DINAS.....	iv
TRANSLITERASI ARAB-LATIN	v
ABSTRAK.....	viii
KATA PENGANTAR	ix
DAFTAR ISI.....	xiii
DAFTAR TABEL.....	xvi
DAFTAR GAMBAR	xvii
DAFTAR LAMPIRAN	xviii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang.....	1
1.2. Identifikasi Masalah	13
1.3. Batasan Masalah.....	14
1.4. Rumusan Masalah	14
1.5. Tujuan Penelitian	15
1.6. Manfaat Penelitian.....	15
BAB II TINJAUAN PUSTAKA.....	17
2.1. Teori Peramalan (<i>Forecasting</i>).....	17
2.2. Pendapatan.....	22

2.2.1.	Sumber-sumber Pendapatan.....	24
2.3.	Artificial Neural Network (ANN).....	25
2.3.1.	Aplikasi <i>Artificial Neural Network</i>	27
2.3.2.	Neuron	28
2.3.3.	Arsitektur Jaringan	30
2.3.4.	Fungsi Aktivasi	31
2.4.	Metode Backpropagation.....	34
2.4.1.	Fungsi Aktivasi	36
2.4.2.	<i>Training Backpropagation</i>	37
2.4.3.	Pembagian Data.....	42
2.5.	Algoritma Genetika.....	44
2.5.1.	Struktur Algoritma Genetika.....	47
2.6.	Kajian Pustaka	60
BAB III METODE PENELITIAN.....		64
3.1.	Jenis Penelitian.....	64
3.2.	Sumber Data.....	64
3.3.	Metode Pengumpulan Data.....	65
3.4.	Metode Analisis Data	66
BAB IV HASIL PENELITIAN DAN PEMBAHASAN		70
4.1.	Deskripsi Data	70
4.2.	Implementasi Metode <i>Backpropagation Artificial Neural Network</i>	71
4.2.1.	Pola <i>Input</i> dan <i>Output</i>	71

4.2.2.	Transformasi Data.....	72
4.2.3.	<i>Transpose</i> Data.....	74
4.2.4.	Pembagian Data.....	75
4.2.5.	Inisialisasi Parameter	75
4.2.6.	Implementasi Proses Training dan Testing <i>Backpropagation Artificial Neural Network</i>	76
4.3.	Implementasi Metode Algoritma Genetika.....	91
4.3.1.	Pengujian Prediksi <i>FeedForward</i> Algoritma Genetika	94
4.4.	Perbandingan Metode <i>Backpropagation Artificial Neural Network</i> dan Algoritma Genetika	96
4.4.1.	Hasil Prediksi Menggunakan <i>Testing Backpropagation Artificial Neural Network</i> dan Algoritma genetika.....	97
BAB V SIMPULAN DAN SARAN		100
5.1.	Simpulan	100
5.2.	Saran.....	101
DAFTAR PUSTAKA.....		103
LAMPIRAN		108
RIWAYAT HIDUP		135

DAFTAR TABEL

Tabel	Judul	Halaman
Tabel 3.1	Data Pendapatan Bulanan JNE Express Sekaran	65
Tabel 4.1	Data Pendapatan JNE Express Sekaran	70
Tabel 4.2	Pola <i>Input</i> dan <i>Output</i>	72
Tabel 4.3	Transformasi Data	73
Tabel 4.4	Transpose Data	74
Tabel 4.5	Parameter Penelitian	76
Tabel 4.6	Karakteristik Arsitektur Jaringan	77
Tabel 4.7	Hasil <i>Training</i> Arsitektur 4-10-1	81
Tabel 4.8	Hasil <i>Testing</i> Arsitektur 4-10-1	81
Tabel 4.9	Hasil <i>Training</i> Arsitektur 4-11-1	85
Tabel 4.10	Hasil <i>Testing</i> Arsitektur 4-11-1	85
Tabel 4.11	Hasil <i>Training</i> Arsitektur 4-12-1	89
Tabel 4.12	Hasil <i>Testing</i> Arsitektur 4-12-1	89
Tabel 4.13	Rekapitulasi Model	91
Tabel 4.14	Perbandingan Data Aktual dan Hasil Prediksi	95
Tabel 4.15	Hasil Perbandingan Metode <i>Backpropagation Artificial Neural Network</i> dan Algoritma Genetika	96
Tabel 4.16	Hasil Prediksi Pendapatan JNE Express Sekaran <i>Backpropagation Artificial Neural Network</i>	97
Tabel 4.17	Hasil Prediksi Pendapatan JNE Express Sekaran Algoritma Genetika	99

DAFTAR GAMBAR

Gambar	Judul	Halaman
Gambar 2.1	Struktur <i>Neural Network</i> secara umum	29
Gambar 2.2	Siklus Algoritma Genetika	47
Gambar 2.3	Contoh penggunaan metode <i>Roulette-Wheel</i>	54
Gambar 2.4	Pindah Silang satu titik potong	56
Gambar 2.5	Pindah Silang banyak titik	57
Gambar 2.6	Pindah Silang seragam	58
Gambar 2.7	Mutasi Satu Gen	59
Gambar 3.1	<i>Flowchart Backpropagation Artificial Neural Network</i>	67
Gambar 3.2	<i>Flowchart</i> Algoritma Genetika	69
Gambar 4.1	Grafik Data Pendapatan JNE Express Sekaran	70
Gambar 4.2	Struktur <i>Neural Network</i> Arsitektur 4-10-1 Secara Umum	79
Gambar 4.3	<i>Nntraintool</i> Arsitektur 4-10-1	79
Gambar 4.4	<i>Plotregression</i> Arsitektur 4-10-1	80
Gambar 4.5	Struktur <i>Neural Network</i> Arsitektur 4-11-1 Secara Umum	83
Gambar 4.6	<i>Nntraintool</i> Arsitektur 4-11-1	83
Gambar 4.7	<i>Plotregression</i> Arsitektur 4-11-1	84
Gambar 4.8	Struktur <i>Neural Network</i> Arsitektur 4-12-1 Secara Umum	87
Gambar 4.9	<i>Nntraintool</i> Arsitektur 4-12-1	87
Gambar 4.10	<i>Plotregression</i> Arsitektur 4-12-1	88
Gambar 4.11	AG BinaryEncoding	93
Gambar 4.12	Struktur FFNN Terbaik	94
Gambar 4.13	Hasil Uji Prediksi	94

DAFTAR LAMPIRAN

Lampiran	Judul
Lampiran 1	Data Pendapatan
Lampiran 2	Pola <i>Input</i> dan <i>Output</i>
Lampiran 3	Normalisasi Data
Lampiran 4	<i>Transpose</i> Data
Lampiran 5	Hasil <i>Training</i> dan <i>Testing</i> Arsitektur 4-10-1
Lampiran 6	Hasil <i>Training</i> dan <i>Testing</i> Arsitektur 4-11-1
Lampiran 7	Hasil <i>Training</i> dan <i>Testing</i> Arsitektur 4-12-1
Lampiran 8	Data Prediksi Pendapatan
Lampiran 9	Syntax Program <i>Backpropagation</i> <i>Artificial Neural Network</i>
Lampiran 10	Syntax Program Algoritma Genetika

BAB I

PENDAHULUAN

1.1. Latar Belakang

Perkembangan dunia yang sangat pesat ini hingga merambah ke dunia digital tidak terlepas dari peran pentingnya matematika. Baik perkembangan teknologi, industri, ekonomi, ataupun politik, hampir disetiap bidang membutuhkan peran matematika. Salah satu ilmu universal dalam perkembangan teknologi modern adalah matematika, hal ini disebabkan karena matematika dapat memberikan bantuan dalam memecahkan masalah berbagai bidang ilmu seperti ilmu alam, teknik, kedokteran, sosial, ekonomi (Simanjuntak, 2021).

Perkembangan teknologi informasi yang sangat pesat pada era ini dapat memberikan banyak kemudahan pada berbagai aspek aktivitas bisnis (Harahap, 2017). Teknologi informasi mempunyai peran pada berbagai aspek aktivitas bisnis, dapat dipahami menjadi sebuah teknologi yang fokus pada pengaturan sistem informasi dengan penggunaan komputer. Teknologi informasi dapat memenuhi kebutuhan informasi dalam dunia bisnis dengan sangat cepat, tepat waktu, relevan, serta akurat.

Perubahan zaman yang terus berkembang kini bisnis *online* semakin banyak, dengan banyaknya pilihan *e-commerce* yang dapat memudahkan banyak orang berbelanja kebutuhannya tanpa harus keluar rumah. Salah satu ekspedisi pengiriman barang, yaitu JNE Express memaksimalkan kualitas pelayanannya untuk memikat pelanggan supaya menggunakan jasa pengirimannya dengan memberikan layanan gratis ongkir dengan minimum harga belanja. JNE Express melakukan cara ini agar tetap mendapatkan keuntungan dari pendapatan tersebut. Kepuasan pelanggan mempunyai hubungan yang signifikan terhadap kesetiaan pelanggan, karena pelanggan yang loyal terbentuk dari pelayanan yang memuaskan (Steven, 2014).

Adanya peluang yang terus berkembang ini memotivasi JNE untuk memperluas jaringannya ke seluruh kota besar yang ada di Indonesia. Saat ini perluasan jaringan JNE telah mencapai lebih dari 6000 titik lokasi dan masih terus bertambah dengan jumlah karyawan yang dimiliki lebih dari 40000 orang. Kehandalan dan komitmen JNE ini dibuktikan dengan adanya pencapaian yang diraih dalam berbagai bentuk

penghargaan serta sertifikasi ISO 9001:2008 atas sistem manajemen mutu (<https://www.jne.co.id/>).

Persaingan pada dunia industri jasa pengiriman yang semakin besar terutama dari sisi bisnis *online* serta tingkat persaingan yang semakin tinggi dimulai dengan munculnya perusahaan-perusahaan baru ekspedisi pengiriman barang. Oleh karena itu, JNE Express harus mampu menumbuhkan loyalitas terhadap pelanggan agar tetap bertahan dalam persaingan di era saat ini. Suatu perusahaan jasa pengiriman harus menumbuhkan kepercayaan terhadap pelanggannya, yaitu salah satunya dengan cara menjamin barang dari pelanggan tersebut sampai kepada tujuan atau pihak yang dituju dengan keadaan sempurna (Yoga, 2015).

Faktor penting dalam operasi suatu perusahaan adalah pendapatan, karena pendapatan akan memberikan pengaruh pada tingkat laba yang diharapkan oleh suatu perusahaan. Pendapatan merupakan penghasilan yang muncul dalam pelaksanaan aktivitas entitas yang biasa serta dikenal dengan sebutan yang berbeda seperti penjualan, imbalan, bunga, dividen, royalti dan sewa (Kusuma & Pratama, 2020).

Menurut Sukirno (2006), Pendapatan juga dapat diartikan sebagai jumlah penghasilan yang diterima oleh seseorang atau penduduk atas prestasi kerjanya selama satu periode tertentu, baik harian, mingguan, bulanan ataupun tahunan. Jenis-jenis pendapatan dibedakan menjadi tiga, yaitu pendapatan total, pendapatan rata-rata, pendapatan marjinal.

Pendapatan total merupakan kuantitas atau jumlah barang yang telah berhasil terjual kemudian dikalikan dengan harga satuan, semakin banyak barang yang terjual maka semakin besar pendapatan total yang diperoleh. Pendapatan rata-rata merupakan pendapatan yang diperoleh dari hasil total penerimaan yang dibagi dengan jumlah barang yang dijual. Pendapatan marjinal merupakan pendapatan tambahan yang didapat dari tambahan penjualan setiap satuan hasil produksi atau penambahan penerimaan atas pendapatan total yang disebabkan oleh penambahan satu unit *output* (Sukirno, 2006).

Peramalan (*forecasting*) merupakan suatu kegiatan untuk memprediksi apa yang akan terjadi pada masa mendatang. Adanya kesenjangan waktu (*timelag*) antara kesadaran dibutuhkannya suatu kebijakan baru dengan waktu pelaksanaan kebijakan tersebut

dibutuhkan peramalan. Metode peramalan dapat memudahkan dalam melakukan pendekatan analisa terhadap tingkah laku atau pola dari data yang lalu. Oleh karena itu, peramalan dapat memberikan cara pemikiran, pengerjaan dan pemecahan yang sistematis dan pragmatis, dan memberikan tingkat keyakinan yang lebih terhadap ketepatan hasil ramalan yang dibuat (Syaharuddin, Adhiim Rizky, et al., 2020).

Forecasting adalah suatu permasalahan penting yang mencakup berbagai bidang termasuk bisnis dan industri, pemerintahan, ekonomi, ilmu lingkungan, medis, ilmu sosial, politik, dan keuangan. Banyak contoh metode yang dapat digunakan untuk peramalan, tetapi metode ini masih tunggal. Artinya metode ini tidak dapat mengolah data majemuk. Oleh karena itu, jenis data yang tersedia harus sesuai agar metode peramalan dapat diterapkan pada data tersebut. Salah satu cara peramalan dapat diterapkan dengan menggunakan GUI *Multimodel Forecasting System* (G-MFS). *Graphic User Interface* (GUI) merupakan MATLAB *script file* yang dibuat untuk memberikan kemudahan dalam menganalisa suatu permasalahan khusus. Terdapat beberapa metode G-MFS diantaranya adalah *Naïve Method*, *Moving Average*,

Exponential Smoothing, dan *Numerical Method* dan *Artificial Neural Network (ANN)* (Syaharuddin, Pujiana, et al., 2020).

Dalam Qur'an Surah Al-Luqman ayat 34, menjelaskan tentang peramalan atau pendugaan sesuatu yang belum pernah terjadi sebelumnya. Allah Subhanahu Wa Ta'ala berfirman (<https://quran.kemenag.go.id/surah/31>):

إِنَّ اللَّهَ عِنْدَهُ عِلْمُ السَّاعَةِ وَيُنَزِّلُ الْغَيْثَ وَيَعْلَمُ مَا فِي الْأَرْحَامِ
وَمَا تَدْرِي نَفْسٌ مَّاذَا تَكْسِبُ غَدًا^ط وَمَا تَدْرِي نَفْسٌ بِأَيِّ أَرْضٍ تَمُوتُ^ع
إِنَّ اللَّهَ عَلِيمٌ خَبِيرٌ

Artinya:

“Sesungguhnya Allah, hanya pada sisi-Nya sajalah pengetahuan tentang Hari Kiamat; dan Dialah yang menurunkan hujan, dan mengetahui apa yang ada dalam rahim. Dan tiada seorangpun yang dapat mengetahui (dengan pasti) apa yang akan diusahakannya besok. Dan tiada seorangpun yang dapat mengetahui di bumi mana dia akan mati. Sesungguhnya Allah Maha Mengetahui lagi Maha Mengenal.”

Kandungan surah Al-Luqman ayat 34 (<https://quranhadits.com/quran/31luqman/luqman-ayat-34/>) menjelaskan bahwa manusia tidak dapat

mengetahui dengan pasti apa yang akan diperolehnya besok, namun bukan berarti manusia tidak berusaha. Akan tetapi, mereka diwajibkan berusaha untuk mendapatkan apa yang Allah turunkan. Apa yang dikerjakan oleh seseorang meskipun seseorang dapat merencanakan sesuatu, tetapi hanya Allah yang dapat mengetahui dengan pasti apa yang akan terjadi esok hari. Namun, semua itu hanya bersifat rencana saja dan jika Allah menghendaki maka akan terlaksana rencana tersebut. Akan tetapi, jika Allah tidak menghendaki maka tidak akan terlaksana rencana tersebut.

Artificial Intelligence merupakan hasil kesimpulan pemetaan yang dilakukan pada pemrograman dengan suatu konsep pemetaan bahasa pemrograman. *Artificial Neural Network* merupakan pemodelan data yang dapat menangkap serta mewakili hubungan *input-output* yang komplek. Hal ini disebabkan karena kemampuannya untuk memecahkan solusi beberapa permasalahan relatif mudah digunakan, kecepatan untuk eksekusi, ketahanan untuk menginput data, dan menginisialisasikan sistem yang rumit (Syaharuddin, Pujiana, et al., 2020).

Metode pembelajaran atau *training* dapat dibedakan menjadi dua macam, yaitu pembelajaran

terawasi (*supervised learning*) dan pembelajaran tak terawasi (*unsupervised learning*). Pada pembelajaran terawasi (*supervised learning*) setiap pola diberikan ke dalam *Artificial Neural Network* yang telah diketahui *output* nya, sedangkan dalam pembelajaran tak terawasi (*unsupervised learning*) tidak memerlukan target *output*. *Backpropagation* merupakan salah satu macam dari algoritma pembelajaran terawasi (*supervised learning*) (Siang, 2005).

Proses pembelajaran dengan menggunakan pengaturan bobot sampai output yang dilakukan oleh *Backpropagation* memperoleh jaringan sinkron yang dibutuhkan. *Neural Network* mempunyai struktur yang terdiri dari beberapa layer. *Backpropagation* pada umumnya digunakan pada jaringan *multi-layer* yang terdiri atas beberapa *hidden unit* dan mempunyai tujuan untuk meminimalkan nilai *error* pada *output* yang dihasilkan oleh jaringan. Hasil peramalan akan menjadi lebih baik jika semakin banyak jumlah *layer* dan *hidden unit* yang ditunjukkan dengan semakin kompleksnya jaringan yang dibangun dan semakin lama waktu yang dibutuhkan untuk *training* (Shaputra et al., 2021).

Artificial Neural Network (ANN) mempunyai beberapa kelemahan, yaitu untuk melakukan suatu operasi numerik dengan presisi tinggi tidak efektif, tidak efisien untuk digunakan pada suatu operasi pada algoritma aritmatik serta simbolis, dalam suatu proses operasi membutuhkan *training*, proses *training* akan memakan waktu yang sangat lama jika datanya berjumlah besar (Azise et al., 2019). Oleh karena itu, diperlukan suatu contoh model optimasi. Ada beberapa contoh model algoritma untuk optimasi yang mampu digunakan pada metode *Artificial Neural Network*. Salah satunya menggunakan model Algoritma Genetika. Algoritma Genetika adalah suatu teknik optimasi yang menggunakan teknik seleksi alam dan genetika alam yang dapat mengeksplorasi pencarian dalam jumlah besar secara efektif sehingga memperoleh hasil yang terbaik (Azise et al., 2019).

Algoritma Genetika merupakan suatu metode yang sangat populer saat ini dan banyak digunakan pada berbagai aplikasi bisnis, teknik maupun bidang lainnya, karena akan menjadi sebuah solusi optimal yang memperoleh hasil terbaik. Pada umumnya Algoritma Genetika digunakan untuk mendapatkan solusi optimal dari persoalan optimasi yang

mempunyai banyak solusi yang mungkin (*feasible solution*). Algoritma Genetika tidak mempunyai jaminan akan selalu menghasilkan solusi optimal dari persoalan-persoalan optimasi. Akan tetapi, pada umumnya Algoritma Genetika dapat memperoleh hasil solusi yang baik setelah melewati proses evolusi (Admi Syarif, 2014).

Dari hasil penelitian terdahulu yang relevan pada kasus prediksi pendapatan dengan metode *Backpropagation Artificial Neural Network* dan dioptimasi menggunakan Algoritma Genetika adalah penelitian yang dilakukan oleh Nur Azise (2019) yang berjudul “Prediksi Pendapatan Penjualan Obat Menggunakan Metode *Backpropagation Neural Network* dengan Algoritma Genetika Sebagai Seleksi Fitur”. Hasil dari *testing* menunjukkan bahwa *Backpropagation Artificial Neural Network* menghasilkan nilai RMSE 0,152, sedangkan pada *testing Backpropagation Artificial Neural Network* dioptimasi menggunakan Algoritma Genetika menghasilkan nilai RMSE 0,115. Dapat disimpulkan bahwa metode *Backpropagation Artificial Neural Network* dengan optimasi Algoritma Genetika terbukti menghasilkan nilai RMSE terbaik daripada model

Backpropagation Artificial Neural Network tanpa optimasi Algoritma Genetika. Oleh karena itu, penelitian ini diajukan untuk mengetahui bahwa metode ini dapat digunakan dalam memprediksi pendapatan dari agen ekspedisi pengiriman barang di Sekaran, Kota Semarang serta mengetahui hasil implementasi dan perbandingan dari kedua metode tersebut.

Suatu metode yang digunakan untuk mengevaluasi peramalan dengan cara menghitung rata-rata selisih kuadrat dari nilai yang diramalkan dan yang diamati dapat disebut *Mean Square Error* (MSE) (Panjaka, 2012). *Root Mean Square Error* (RMSE) merupakan alat seleksi model yang diperoleh dari *error* hasil estimasi. Nilai ini digunakan untuk menentukan model mana yang terbaik dan akurat, apabila besar tingkat kesalahan yang menghasilkan prediksi semakin kecil (mendekati 0) (Wahyuningsih, 2012).

Suatu metode yang digunakan untuk menghitung ukuran presentase penyimpangan antara data aktual dengan data peramalan disebut *Mean Absolute Percentage Error* (MAPE). MAPE dapat dihitung dengan menggunakan kesalahan absolut atau mutlak pada tiap periode yang dibagi dengan nilai observasi

nyata untuk periode itu. Adapun kemampuan model peramalan sangat baik apabila mempunyai nilai MAPE kurang dari 10% dan jika mempunyai nilai MAPE kurang dari 20%, maka kemampuan model peramalan ini baik (Kristien Margi S., 2015)

Selain itu, berdasarkan data yang telah diamati tidak banyak agen ekspedisi pengiriman barang yang terdapat di Sekaran. Total pendapatan perbulannya hingga mencapai puluhan juta, dengan demikian ini merupakan data yang berjumlah besar. Mengutip beberapa kelemahan dari metode *backpropagation neural network* salah satunya adalah proses *training* membutuhkan waktu yang sangat lama. Namun, dengan menggunakan model optimasi Algoritma Genetika diharapkan mampu mengeksplorasi pencarian data berjumlah besar secara efektif sehingga mendapatkan hasil atau nilai RMSE terbaik dan akurat.

Penelitian ini mengkaji serta membahas tentang Implementasi Metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika Terhadap Estimasi Pendapatan Agen Ekspedisi Pengiriman Barang. Ekspedisi pengiriman barang ini adalah JNE Express Sekaran, GunungPati, Kota Semarang.

1.2. Identifikasi Masalah

Berdasarkan latar belakang yang telah diuraikan di atas, maka dapat diidentifikasi masalah sebagai berikut:

1. *Artificial Neural Network* (ANN) mempunyai beberapa kelemahan, yaitu tidak efektif untuk melakukan operasi numerik dengan presisi tinggi, untuk melakukan operasi *Neural Network* membutuhkan *training* yang memakan waktu sangat lama apabila datanya berjumlah besar.
2. Mengatasi permasalahan data berjumlah besar dalam melakukan proses *training* dapat menggunakan model algoritma genetika. Teknik optimasi ini mampu mengeksplorasi pencarian dalam jumlah besar secara efektif.
3. Agen ekspedisi pengiriman barang, yaitu JNE Express di Sekaran ini masih terbilang sedikit, namun bukan berarti agen ekspedisi pengiriman barang ini tidak dapat mencapai total pendapatannya hingga puluhan juta perbulan.

1.3. Batasan Masalah

Batasan masalah dalam penelitian ini adalah:

1. Ruang lingkup meliputi pendapatan agen ekspedisi pengiriman barang yaitu JNE Express Sekaran, GunungPati, Kota Semarang.
2. Data yang digunakan dalam penelitian ini adalah data pendapatan bulanan tahun 2019-2021.
3. Barang yang dikirim oleh pelanggan meliputi pakaian, alat elektronik, alat kosmetik, dokumen hingga kargo seperti motor. Pada penelitian ini jumlah paket barang termasuk variabel penelitian.

1.4. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan di atas, secara garis besar rumusan masalah yang peneliti tentukan adalah sebagai berikut:

1. Bagaimana implementasi metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika untuk estimasi pendapatan agen ekspedisi pengiriman barang (JNE Express Sekaran)?
2. Bagaimana analisis hasil perbandingan antara metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika?

1.5. Tujuan Penelitian

Adapun tujuan penelitian yang ingin dicapai adalah sebagai berikut:

1. Mengetahui hasil implementasi antara metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika terhadap estimasi pendapatan agen ekspedisi pengiriman barang (JNE Express Sekaran).
2. Mengetahui hasil perbandingan antara metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika.

1.6. Manfaat Penelitian

Berdasarkan tujuan di atas, maka diperoleh manfaat penelitian sebagai berikut:

1. Manfaat Teoritis
 - a. Setelah mengetahui hasil implementasi metode *Backpropagation Artificial Neural Network* dengan menggunakan Algoritma Genetika untuk estimasi pendapatan pada agen ekspedisi pengiriman barang, yaitu JNE Express di Sekaran, maka dapat memberikan informasi untuk meningkatkan kualitas yang dimiliki JNE Express Sekaran agar tetap mendapatkan pendapatan yang stabil atau meningkat.

- b. Setelah mengetahui nilai RMSE yang diperoleh, maka dapat disimpulkan bahwa agar mendapatkan nilai RMSE terbaik dengan menggunakan model optimasi algoritma genetika.
2. Manfaat Praktis
- a. Dapat menambah wawasan dan pengalaman langsung cara menggunakan metode *Backpropagation Artificial Neural Network* dan mengetahui model optimasi Algoritma Genetika.
 - b. JNE Express Sekaran dapat menggunakan hasil ini sebagai bahan evaluasi dan pertimbangan ke depan guna pengembangan pendapatan yang diperoleh JNE Express Sekaran.

BAB II

TINJAUAN PUSTAKA

2.1. Teori Peramalan (*Forecasting*)

Menurut Zulian Yamit (2003) peramalan (*forecasting*) merupakan alat bantu yang penting dalam perencanaan yang efektif serta efisien, khususnya dalam bidang ekonomi. Pada umumnya peramalan juga mempunyai peran pribadi pada suatu peristiwa eksternal yang berada diluar kendali manajemen seperti ekonomi, sosial, politik, perubahan teknologi, budaya, pemerintah, pelanggan, pesaing dan lainnya.

Peramalan (*forecasting*) adalah sebuah prediksi, proyeksi, atau estimasi dari ketidakpastian masa yang akan datang. Kegiatan peramalan biasanya adalah sebagai berikut (Tersine, 1994):

1. Sebagai alat bantu dalam perencanaan yang efektif dan efisien.
2. Untuk menentukan kebutuhan sumber daya di masa yang akan datang.
3. Untuk membuat suatu keputusan yang tepat.

Peramalan juga merupakan hal yang diperkirakan untuk kebutuhan masa yang akan datang dengan

mencakup kebutuhan dalam ukuran kuantitas atau jumlah, kualitas atau mutu, waktu lokasi yang dibutuhkan untuk memenuhi permintaan barang atau jasa (Rau, 2018).

Metode dari peramalan secara luas dapat digolongkan menjadi empat jenis yaitu (Chatfield, 2000):

1. Metode peramalan *Judgemental* berdasarkan atas penilaian subjektif, intuisi, dalam pengetahuan komersial, dan informasi terkait lainnya.
2. Metode Univariat di mana suatu peramalan bergantung pada nilai-nilai sekarang dan masa lalu variabel tunggal yang diperkirakan ataupun dapat ditambah dengan fungsi waktu sebagaimana *tren linier*.
3. Metode Multivariat di mana perkiraan variabel dependen tertentu ditentukan oleh nilai satu atau lebih *time series* variabel tambahan disebut juga sebagai variabel penjelas.
4. Metode Kombinasi yang mana penggabungan lebih dari satu pendekatan di atas contohnya, ketika metode univariat atau multivariat dikombinasikan dengan metode *judgemental* untuk menghitung

informasi eksternal yang sulit untuk menjelaskan secara resmi dalam model matematis.

Berdasarkan periode waktunya, peramalan dapat digolongkan menjadi 3 bentuk yaitu (Montgomey et al., 2008):

1. Jangka Pendek (*Short Term*)

Suatu peramalan yang terjadi dalam beberapa periode waktu tertentu seperti hari, minggu, bulan ke depan. Waktu peramalannya sangat singkat, oleh karena itu data riwayat masa lalu masih cukup relevan untuk meramalkan masa datang. Misalnya dalam peramalan jangka pendek (*short term*) adalah prediksi penjualan atau produksi.

2. Jangka Menengah (*Medium Term*)

Estimasi jangka menengah (*medium term*) menjadikan periode waktu lebih panjang dari satu sampai dua tahun ke depan. Peramalan jangka menengah masih menggunakan metode kuantitatif dan kualitatif karena data riwayat masa lalu masih cukup relevan untuk meramalkan masa datang. Misalnya meramalkan anggaran penjualan atau produksi.

3. Jangka Panjang (*Long Term*)

Rentang periode waktu lebih dari dua tahun disebut juga Jangka Panjang (*Long Term*). Pada umumnya peramalan jangka panjang digunakan berdasarkan atas intuisi dan pengalaman hidup seseorang. Akan tetapi, sebuah instansi atau perusahaan banyak juga yang menggunakan data riwayat.

Tujuan dari sebuah peramalan adalah untuk mendapatkan hasil peramalan yang dapat meminimumkan kesalahan atau *error* meramal (*forecast error*) yang diukur dengan menggunakan *Mean Absolute Percentage Error* (MAPE), *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE). Sehingga dengan adanya metode peramalan, produksi manajemen perusahaan akan memperoleh suatu gambaran keadaan produksi pada masa yang akan datang serta mampu memberikan kemudahan manajemen perusahaan (Gufron et al., 2014).

1. ***Mean Absolute Percentage Error* (MAPE)**

Mean Absolute Percentage Error (MAPE) merupakan rata-rata dari jumlah seluruh kesalahan atau *error* persentase pada suatu kumpulan data tertentu yang diambil tanpa melihat tanda positif

atau negatif. Maksudnya adalah nilai absolut atau mutlaknya dioperasikan dengan menjumlahkan dan dihitung rata-rata, MAPE dapat dirumuskan sebagai berikut (Makridakis S et al., 1999):

$$MAPE = \left(\frac{100\%}{n} \right) \sum_{t=1}^n \frac{|X_t - F_t|}{X_t} \quad (2.1)$$

Di mana:

n = Jumlah data

X_t = Nilai aktual

F_t = Nilai ramalan

2. Mean Square Error (MSE)

Mean Square Error (MSE) merupakan salah satu metode pengukuran yang digunakan untuk menentukan besar tingkat kesalahan atau *error* dari suatu peramalan. Cara menentukan nilai MSE dengan mengkuadratkan selisih antara data ramalan dengan data aktual sehingga nilai *error* akan menjadi positif. MSE dapat dirumuskan sebagai berikut (Makridakis S et al., 1999):

$$MSE = \frac{\sum_{t=1}^n e^2}{n} \quad (2.2)$$

Di mana:

e = Nilai *error* (nilai aktual dikurangi nilai ramalan)

n = Jumlah data

3. *Root Mean Square Error (RMSE)*

Perbedaan antara *Root Mean Square Error* (RMSE) dan *Mean Square Error* (MSE) adalah untuk menentukan nilai RMSE dengan menggunakan akar setelah memperoleh nilai MSE. *Root Mean Square Error* (RMSE) merupakan suatu nilai alternatif dengan mengevaluasi teknik peramalan yang akan digunakan untuk mendapatkan model terbaik dengan menentukan tingkat akurasi hasil prakiraan suatu model. Nilai RMSE yang rendah berarti bahwa variasi nilai yang diperoleh dari suatu model prakiraan mendekati variasi nilai observasinya, RMSE dapat dirumuskan sebagai berikut (Laksana, 2017):

$$RMSE = \sqrt{\frac{\sum_{t=1}^n |X_t - F_t|^2}{n}} \quad (2.3)$$

Di mana:

X_t = Data sebenarnya

F_t = Data ramalan dihitung dari model yang digunakan pada waktu / tahun t

n = Banyak data hasil ramalan

2.2. **Pendapatan**

Pendapatan adalah suatu hasil yang diperoleh seseorang atau rumah tangga dengan berusaha atau bekerja. Profesi masyarakat umum beragam macam,

seperti bertani, nelayan, beternak, buruh, serta berdagang dan juga ada yang bekerja pada sektor pemerintah dan swasta. Menurut Hicks pendapatan merupakan jumlah yang dikonsumsi oleh seseorang selama jangka periode waktu tertentu. Sementara itu, Henry C Simon yang memandang dari sudut pendapatan perorangan, mengatakan bahwa pendapatan menjadi jumlah dari nilai pasar barang dan jasa yang dikonsumsi dan perubahan nilai kekayaan yang ada pada awal dan akhir satu periode (Saragih, M.Sc, 2017).

Pendapatan menurut Ilmu Ekonomi merupakan suatu nilai maksimum yang mampu dikonsumsi oleh seseorang dalam suatu periode tertentu dengan mengharapakan keadaan yang sama pada akhir periode seperti keadaan semula. Pengertian pendapatan menurut Ilmu Ekonomi mengutamakan total kuantitatif pengeluaran terhadap konsumsi selama satu periode (Fauzan Haqiqi et al., 2020). Dengan istilah lain pengertian pendapatan menurut Ilmu Ekonomi adalah jumlah harta kekayaan awal periode ditambah keseluruhan hasil yang diperoleh selama satu periode, bukan hanya yang dikonsumsi.

Konsep pendapatan dapat mengukur keadaan seseorang dengan menunjukkan jumlah secara keseluruhan uang yang diperoleh seseorang atau rumah tangga selama jangka periode waktu tertentu. Total pendapatan (uang atau bukan uang) yang diperoleh seseorang atau rumah tangga selama periode tertentu dapat diartikan sebagai pendapatan (Rahardja dan Manurung, 2010).

2.2.1. Sumber-sumber Pendapatan

Secara umum pendapatan diperoleh dari tiga (3) sumber, yaitu (Samuelson dan Nordhaus, 2005):

a. Gaji dan upah

Seseorang memperoleh hasil imbalan setelah melakukan suatu pekerjaan untuk pihak tertentu seperti orang lain, perusahaan swasta, atau pemerintah.

b. Pendapatan dari kekayaan

Pendapatan dari kekayaan dapat diartikan sebagai nilai dari total suatu produksi yang dikurangi dengan biaya yang dikeluarkan baik dalam bentuk uang ataupun dalam bentuk lainnya seperti tenaga kerja,

keluarga, dan nilai sewa kapital untuk diri sendiri yang tidak diperhitungkan.

c. Pendapatan dari sumber lain

Pendapatan dari sumber lain menunjukkan bahwa memperoleh pendapatan dengan cara tanpa mencurahkan tenaga kerja antara lain penerimaan dari pemerintah, asuransi pengangguran, menyewa aset, bunga bank, dan sumbangan dalam bentuk apapun serta laba dari suatu usaha. Tingkat pendapatan (*income level*) merupakan tingkat pendapatan yang mampu dinikmati oleh seseorang baik individu ataupun keluarga berdasarkan penghasilan mereka atau dari sumber-sumber pendapatan yang lain.

2.3. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) dapat disebut juga sebagai Jaringan Syaraf Tiruan (JST) merupakan suatu konsep pengetahuan yang terdapat pada bidang *Artificial Intelligent* (Kecerdasan Buatan) dengan mengambil desain pada sistem saraf manusia. Bagian terkecil dari otak manusia yang mempunyai fungsi untuk menjadi pemroses informasi merupakan sel saraf. Sel saraf tersebut sering disebut sebagai neuron

(Eko Prasetyo, 2014). Terdapat sebuah unit pada struktur *Neural Network* yang berfungsi untuk memproses neuron yang terdiri dari *adder* serta fungsi aktivasi yang mengatur *output* dari neuron, bobot, vektor masukan (*input*) (Azise et al., 2019).

Artificial Neural Network (ANN) dapat diartikan juga sebagai suatu sistem yang menjadi pemroses informasi yang mempunyai ciri khas atau karakteristik serupa dengan jaringan saraf biologi. *Artificial Neural Network* menjadi proses generalisasi model matematika yang terdapat pada jaringan saraf biologi berdasarkan landasan bahwa (Siang, 2005):

1. Banyak elemen sederhana (neuron) yang terjadi dari suatu pemrosesan informasi.
2. Neuron akan mendapatkan sinyal dari penghubung-penghubung.
3. Penghubung-penghubung ini mempunyai bobot yang dapat memperkuat atau memperlemah kekuatan sinyal.
4. Dalam menentukan suatu *output*, fungsi aktivasi yang digunakan pada setiap neuron disesuaikan pada jumlah *input* yang diperoleh. Besarnya *output* yang dihasilkan selanjutnya akan dibandingkan dengan suatu batas ambang.

Artificial Neural Network ditunjukkan oleh 3 hal diantara lain:

1. Arsitektur jaringan yang berarti pola hubungan antar neuron.
2. Metode *training* yang berfungsi untuk menentukan bobot penghubung.
3. Fungsi aktivasi.

2.3.1. Aplikasi *Artificial Neural Network*

Artificial neural network memiliki beberapa aplikasi sebagai berikut (Siang, 2005):

1. Pengenalan pola (*Pattern Recognition*)

Pengenalan pola menunjukkan bahwa *Artificial Neural Network* dapat digunakan untuk mengenali pola seperti huruf, angka, suara, atau tanda tangan yang sudah berubah.

2. *Signal Processing*

Artificial Neural Network juga mempunyai fungsi untuk menekan noise dalam saluran telepon.

3. Peramalan (*Forecasting*)


Artificial Neural Network juga dapat digunakan untuk meramalkan sesuatu yang akan terjadi pada masa yang akan datang

berdasarkan sesuai pola kejadian yang terjadi pada masa lampau.

2.3.2. Neuron

Neuron merupakan unit pemrosesan informasi yang menjadi landasan dari penggunaan *Artificial Neural Network*. Neuron terbentuk dari tiga elemen, yaitu (Siang, 2005):

1. Himpunan dari beberapa unit yang dihubungkan dengan jalur koneksi mempunyai bobot unit yang tidak sama. Adapun bobot unit yang bernilai positif berfungsi untuk memperkuat sinyal, sedangkan bobot unit yang bernilai negatif berfungsi untuk memperlemah sinyal yang dibawanya. Unit-unit yang terdiri dari jumlah, struktur, dan pola hubungan tersebut akan menentukan arsitektur jaringan dan model jaringan.
2. *Input-input* sinyal yang sudah disilangkan dengan bobotnya akan dijumlahkan oleh suatu unit penjumlah.
3. Sinyal dari *input* neuron ditentukan oleh fungsi aktivasi yang akan dibagikan ke neuron lain atau tidak.



Gambar 2.1 Struktur *Neural Network*
Secara Umum (Sujoto T, 2010)

Penentuan *hidden layer* pada metode *Artificial Neural Network* sangat penting, karena jumlah neuron dari *hidden layer* yang akan digunakan sangat berpengaruh terhadap perubahan hasil dari *training* jaringan tersebut. Apabila jumlah neuron dari *hidden layer* terlalu sedikit, maka data yang dihasilkan oleh jaringan tersebut sering kali tidak relevan. Akan tetapi, jika jumlah neuron terlalu banyak akan menghambat proses *training* dari jaringan tersebut dan akan terjadi *training* tak terhingga. Oleh karena itu, diperlukan suatu pencocokan terhadap jumlah neuron dari *hidden layer* yang digunakan (Jeff Heaton, 2008).

Aturan yang digunakan dalam menentukan jumlah neuron dari *hidden layer* yang tepat

untuk setiap jaringan sangat banyak. Aturan-aturan yang sering dipakai adalah sebagai berikut:

1. Jumlah neuron dari *hidden layer* lebih besar dari jumlah pola *input* atau *output*.
2. Jumlah neuron dari *hidden layer* sebaiknya 2 atau 3 lebih besar dari jumlah pola *input* ditambah dengan jumlah pola *output*.
3. Jumlah neuron dari *hidden layer* harus lebih kecil dari atau sama dengan dua kali jumlah pola *input*.

2.3.3. Arsitektur Jaringan

Arsitektur jaringan merupakan pola keterhubungan antar neuron. Penyusun jaringan saraf tiruan mempunyai lapisan-lapisan yang terbagi menjadi tiga bagian, yaitu (Puspitaningrum, 2006):

1. *Input Layer*

Unit yang terdapat pada *input layer* dapat disebut dengan neuron *input*. Neuron-neuron input memperoleh *input* dari luar. *Input* yang dimasukkan merupakan penggambaran dari suatu masalah.

2. *Hidden Layer*

Unit yang terdapat pada *hidden layer* dapat disebut dengan neuron tersembunyi. Lapisan tersembunyi tidak dapat langsung diamati oleh *output*.

3. *Output Layer*

Unit yang terdapat pada *output layer* dapat disebut dengan neuron *output*. *Output* dari lapisan ini merupakan *output* jaringan saraf tiruan terhadap suatu permasalahan.

2.3.4. Fungsi Aktivasi

Fungsi aktivasi berfungsi untuk menentukan *output* dari suatu neuron. Beberapa fungsi aktivasi yang sering digunakan sebagai berikut (Siang, 2005):

1. Fungsi *threshold* (batas ambang)

Fungsi *threshold* atau disebut juga dengan fungsi *heavy side* dirumuskan menjadi sebagai berikut:

$$f(x) = \begin{cases} 1, & x \geq \alpha \\ 0, & x < \alpha \end{cases} \quad (2.4)$$

Untuk beberapa kasus fungsi *threshold* yang dibuat bukan pada range (0,1) tapi pada range (-1,1) sering disebut *threshold* bipolar, dapat dirumuskan sebagai berikut:

$$f(x) = \begin{cases} -1, & x \geq \alpha \\ 0, & x < \alpha \end{cases} \quad (2.5)$$

2. Fungsi Sigmoid

Nilai fungsi sigmoid terletak antara 0 dan 1. Selain itu, fungsi sigmoid juga mampu diturunkan dengan mudah. Fungsi sigmoid biner dapat dirumuskan sebagai berikut:

$$f(x) = \frac{1}{1+e^{-x}} \text{ dengan} \\ f'(x) = f(x)(1 - f(x)) \quad (2.6)$$

Dengan pembuktian $f'(x)$ menggunakan aturan rantai sebagai berikut:

$$\begin{aligned} f'(x) &= f(x)(1 - f(x)) \\ \frac{d(1 + e^{-x})^{-1}}{d(1 + e^{-x})} \cdot \frac{d(1 + e^{-x})}{dx} \\ &= -1(1 + e^{-x})^{-2} \cdot \frac{d(1 + e^{-x})}{dx} \\ &= -1(1 + e^{-x})^{-2} \cdot \left(\frac{d(1)}{dx} + \frac{d(e^{-x})}{dx} \right) \\ &= (1 + e^{-x})^{-2} (e^{-x}) \\ &= \frac{e^{-x}}{(1 + e^{-x})^2} = \frac{1 - 1 + e^{-x}}{(1 + e^{-x})^2} \\ &= \frac{1 + e^{-x}}{(1 + e^{-x})^2} - \frac{1}{(1 + e^{-x})^2} \\ &= \frac{1}{(1 + e^{-x})} - \frac{1}{(1 + e^{-x})^2} \\ &= \frac{1}{(1 + e^{-x})} \left(1 - \frac{1}{(1 + e^{-x})} \right) \end{aligned}$$

$$= f(x)(1 - f(x))$$

Selain sigmoid biner, fungsi sigmoid bipolar juga sering digunakan dan bentuk fungsinya serupa dengan fungsi sigmoid biner, hanya saja dengan range $(-1,1)$. Fungsi sigmoid bipolar dapat dirumuskan sebagai berikut:

$$f(x) = \frac{1-e^{-x}}{(1+e^{-x})} \text{ dengan}$$

$$f'(x) = \frac{(1+f(x))(1-f(x))}{2} \quad (2.7)$$

Menyelesaikan hasil dari fungsi turunan sigmoid bipolar terlebih dahulu sebelum membuktikan menggunakan rumus $y = \frac{u}{v}$ sebagai berikut:

$$\begin{aligned} f'(x) &= \frac{(1+f(x))(1-f(x))}{2} \\ &= \frac{\left(1 + \left(\frac{1-e^{-x}}{1+e^{-x}}\right)\right)\left(1 - \left(\frac{1-e^{-x}}{1+e^{-x}}\right)\right)}{2} \\ &= \frac{\left(\frac{1+e^{-x}}{1+e^{-x}} + \frac{1-e^{-x}}{1+e^{-x}}\right)\left(\frac{1+e^{-x}}{1+e^{-x}} - \frac{1-e^{-x}}{1+e^{-x}}\right)}{2} \\ &= \frac{\left(\frac{2}{1+e^{-x}}\right)\left(\frac{2e^{-x}}{1+e^{-x}}\right)}{2} \end{aligned}$$

$$\begin{aligned}
&= \frac{4e^{-x}}{(1+e^{-x})^2} \\
&= \frac{4e^{-x}}{(1+e^{-x})^2} \cdot \frac{1}{2} = \frac{2e^{-x}}{(1+e^{-x})^2}
\end{aligned}$$

Dengan pembuktian $f'(x)$ menggunakan

rumus $y = \frac{u}{v}$ sebagai berikut:

$$u = 1 - e^{-x}, u' = e^{-x} \text{ dan } v = 1 + e^{-x}, v' = -e^{-x}$$

$$\begin{aligned}
y &= \frac{u' \cdot v - v' \cdot u}{v^2} \\
&= \frac{e^{-x}(1+e^{-x}) - (-e^{-x})(1-e^{-x})}{(1+e^{-x})^2} \\
&= \frac{e^{-x} + e^{-2x} + e^{-x} - e^{-2x}}{(1+e^{-x})^2} = \frac{2e^{-x}}{(1+e^{-x})^2} \\
&= \frac{(1+f(x))(1-f(x))}{2}
\end{aligned}$$

3. Fungsi Identitas

Fungsi identitas yang sering digunakan apabila kita menginginkan suatu *output* jaringan sembarang bilangan riil yaitu tidak hanya pada range (0,1) atau (-1,1).

$$f(x) = x \quad (2.8)$$

2.4. Metode Backpropagation

Terdapat beberapa teknik *training* dalam *neural network* salah satunya adalah propagasi balik

(*Backpropagation*) yang merupakan salah satu jenis dari algoritma pembelajaran terawasi (*supervised learning*). *Backpropagation* melakukan proses *training* jaringan untuk memperoleh keseimbangan antara kemampuan jaringan dengan mengetahui pola yang akan digunakan selama *training* serta kemampuan jaringan akan membagikan respon yang benar atas pola *input* yang mirip dengan pola yang akan digunakan selama proses *training* (Siang, 2005).

Backpropagation Artificial Neural Network (BANN) dapat berarti sebagai sejenis multilayer dengan *feed-forward Network* berdasarkan atas algoritma *Backpropagation Artificial Neural Network* yang menggunakan nilai *error* data pada proses *training*. Terdapat proses propagasi maju dan balik atas penggunaan algoritma *Backpropagation Artificial Neural Network* (Sun Wei and Xu Yanfeng, 2015). Nilai *error output* pada algoritma *Backpropagation Artificial Neural Network* mempunyai peran untuk membarui nilai bobot dengan proses *backward*. Tahap yang harus dikerjakan untuk memperoleh nilai *error* adalah menggunakan *forward propagation* (propagasi maju), dengan mengaktifkan neuron-neuron melalui aktivasi *sigmoid*, dengan persamaan (Kusumadewi Sri, 2003).

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

2.4.1. Fungsi Aktivasi

Pada metode *backpropagation*, fungsi aktivasi yang akan digunakan wajib memenuhi syarat yaitu: kontinu, terdiferensial dengan mudah yang berarti juga fungsi yang tidak turun. Salah satu fungsi yang memenuhi syarat tersebut dan sering digunakan dalam metode *Backpropagation* adalah fungsi sigmoid biner yang memiliki range (0,1). Fungsi sigmoid mempunyai nilai maksimum = 1. Sehingga untuk pola yang targetnya mempunyai nilai lebih besar daripada satu, pola *input* dan *output* harus terlebih dahulu ditransformasi atau dinormalisasi hingga semua polanya mempunyai range yang sama dengan fungsi sigmoid yang digunakan. Data mampu ditransformasikan ke range (0,1). Akan tetapi, menjadi lebih baik apabila ditransformasikan atau dinormalisasikan ke range yang lebih kecil, misalnya range (0.1, 0.9). Hal ini disebabkan karena fungsi sigmoid biner merupakan fungsi asimtotik yang nilainya tidak pernah memperoleh angka 0 atau 1. Data dapat

ditransformasi atau dinormalisasi menggunakan rumus dari metode normalisasi *min-max* sebagai berikut (Siang, 2005):

$$X' = \frac{0,8(x-a)}{b-a} + 0,1 \quad (2.10)$$

Dimana:

x = Data asli

X' = Data normalisasi

a = Data minimum

b = Data maksimum

Sedangkan untuk mengembalikan data ke bentuk asli atau disebut juga dengan denormalisasi dapat menggunakan rumus sebagai berikut (Siang, 2005):

$$x = \frac{(X'-0,1)(b-a)}{0,8} + a \quad (2.11)$$

2.4.2. Training Backpropagation

Training Backpropagation mencakup tiga fase, yaitu sebagai berikut:

1. Fase maju merupakan fungsi aktivasi yang ditentukan digunakan untuk pola masukan dengan menghitung maju mulai dari layar *input* hingga layar *output*.
2. Fase mundur merupakan selisih antara *output* jaringan dengan target yang ingin dicapai merupakan kesalahan yang terjadi.

Sehinggakesalahan tersebut dipropagasikan mundur dimulai dari garis yang berhubungan langsung dengan unit-unit di layar *output*.

3. Modifikasi bobot dan bias berfungsi untuk menurunkan kesalahan yang terjadi.

Secara rinci dapat diuraikan sebagai berikut (Puspitaningrum, 2006):

- Langkah 1 : Inisialisasi bobot-bobot, konstanta laju *training* (α), toleransi *error* atau nilai bobot (bila menggunakan nilai bobot sebagaikondisi berhenti) atau set maksimal *epoch* (jika menggunakan banyak *epoch* sebagai kondisi berhenti).
- Langkah 2 : Jika kondisi berhenti belum dicapai, maka lakukan langkah ke tiga hingga langkah ke sepuluh.
- Langkah 3 : Untuk setiap pasangan pola *training*, lakukan langkah ke empat hingga langkah ke sembilan.

1. Tahap Umpan maju (*feedforward propagation*)

Langkah 4 : Masing-masing *input*

$(X_i, i = 1, 2, 3, \dots n)$ menerima sinyal X_i , kemudian melanjutkan ke semua unit pada lapisan tersembunyi.

Langkah 5 : Pada masing-masing lapisan tersembunyi (dari unit ke 1 hingga ke unit ke n) dikalikan dengan bobotnya dan dijumlahkan serta ditambahkan biasnya:

$$z_{net_j} = v_{0j} + \sum_{i=1}^n X_i V_{ij} \quad (2.12)$$

$$z_j = f(z_{net_j}) = \frac{1}{1 + e^{-z_{net_j}}} \quad (2.13)$$

Langkah 6 : Masing-masing unit *output*

$(Y_k, k = 1, 2, 3, \dots m)$ dikalikan dengan bobot dan dijumlahkan serta ditambahkan biasnya:

$$y_{net_j} = w_{0k} + \sum_{j=1}^p z_j k_j \quad (2.14)$$

$$y_k = f(y_{net_k}) = \frac{1}{1 + e^{-y_{net_k}}} \quad (2.15)$$

2. Tahap Umpan mundur (*backward propagation*)

Langkah 7 : Pada masing-masing unit *output* ($Y_k, k = 1, 2, 3, \dots m$) menerima target sesuai *input training*, selanjutnya menghitung nilai *error*. *Output* dikirim ke lapisan bawahnya dan digunakan untuk menghitung besarnya koreksi bobot dan bias (Δw_{jk} dan Δw_{0k}) antara lapisan tersembunyi dengan lapisan *output*).

$$\begin{aligned}\delta_k &= (t_k - y_k)f'(y_{net_k}) \\ &= (t_k - y_k)y_k(1 - y_k) \quad (2.16)\end{aligned}$$

f' = turunan dari fungsi aktivasi

Untuk menghitung koreksi bobot menggunakan persamaan:

$$\Delta w_{jk} = \alpha \delta_k z_j; \quad (2.17)$$

$$k = 1, 2, 3, \dots m; j = 0, 1, \dots n$$

Untuk menghitung koreksi bias menggunakan persamaan:

$$\Delta w_{0k} = \alpha \delta_k \quad (2.18)$$

Langkah 8 : Pada masing-masing unit tersembunyi ($Z_j, j = 1, 2, 3, \dots p$) dilakukan perhitungan informasi *error* lapisan tersembunyi, kemudian digunakan untuk menghitung besar koreksi bobot dan bias (Δv_{ji} dan Δv_{0j}) antara lapisan *input* dan lapisan tersembunyi.

$$\delta_{net} = \sum_{k=1}^m \delta_k w_{jk} \quad (2.19)$$

Untuk menghitung informasi *error*, dengan mengalikan nilai ini dengan turunan dari fungsi aktivasinya, yaitu dengan persamaan:

$$\begin{aligned} \delta_j &= \delta_{net} f'(\delta_{net_j}) \\ &= \delta_{net_j} z_j (1 - z_j) \end{aligned} \quad (2.20)$$

Hitung koreksi bobot menggunakan persamaan:

$$\Delta v_{ji} = \alpha \delta_j x_i \quad (2.21)$$

Hitung koreksi bias menggunakan persamaan:

$$\Delta v_{0j} = \alpha \delta_j \quad (2.22)$$

3. Tahap perubahan pada bobot dan bias

Langkah 9 : Pada masing-masing unit *output* ($Y_k, k = 1, 2, 3, \dots m$) dilakukan perubahan pada bobot dan bias ($j=0, 1, 2, 3, \dots p$) sehingga menghasilkan bobot dan bias baru:

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (2.23)$$

Pada masing-masing unit tersembunyi ($Z_j, j = 1, 2, 3, \dots p$) dilakukan perubahan bobot dan bias ($i=0, 1, 2, \dots n$):

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (2.24)$$

Langkah 10 : Tes kondisi berhenti.

2.4.3. Pembagian Data

Penggunaan *Backpropagation* mempunyai tujuan untuk memperoleh keseimbangan antara pengenalan pola *training* secara benar dan juga respon yang baik untuk pola lain yang sejenis disebut dengan data *testing*. Pada umumnya, data akan dibagi menjadi dua bagian, yaitu pola data yang digunakan sebagai *training* dan data yang digunakan untuk proses

testing (Rufiyanti, 2015). Adapun komposisi data *training* dan *testing* yang sering digunakan dalam metode *backpropagation* adalah sebagai berikut:

1. 80% untuk data *training* dan 20% untuk data *testing*.
2. 70% untuk data *training* dan 30% untuk data *testing*.
3. $\frac{1}{3}$ untuk data *training* dan $\frac{2}{3}$ untuk data *testing*.
4. 50% untuk data *training* dan 50% untuk data *testing*.
5. 60% untuk data *training* dan 40% untuk data *testing*.

Menurut Zhang (1997) beberapa peneliti sering membagi data *training* dan *testing* dengan menggunakan komposisi 80% untuk data *training* dan 20% untuk data *testing*. Masalah dalam pembagian data harus diperhatikan agar jaringan memperoleh data *training* yang cukup dan data *testing* dapat melakukan proses *testing* dari hasil *training* yang dilakukan berdasarkan nilai MAPE data *training* dan *testing*. Jaringan bisa jadi tidak

menjamin untuk dapat mempelajari hasil data dengan baik. Hal ini disebabkan karena jumlah bilangan data yang kurang untuk proses *training*. Sebaliknya, jumlah data yang terlalu banyak dalam proses *training* mungkin akan memperlambat proses pemusatan (konvergensi). Masalah *overtraining* (data *training* yang berlebihan) akan menyebabkan jaringan cenderung untuk menghafal data yang dimasukkan daripada menggeneralisasi data.

2.5. Algoritma Genetika

Suatu metode *heuristic* yang mengembangkan teori Evolusi Darwin berdasarkan sesuai prinsip genetika dan proses seleksi alamiah. Selanjutnya metode ini dikembangkan menjadi metode optimasi oleh John Holland pada tahun 1960-an (Zukhri, 2014). Algoritma Genetika merupakan salah satu algoritma atau metode yang mempunyai peran untuk menyelesaikan permasalahan optimasi. Setiap hasil solusi yang diperoleh untuk menyelesaikan permasalahan pada Algoritma Genetika disebut dengan kromosom (individu), setiap kromosom terdiri dari gen (Jadav Kinjal and Pancal Mahesh, 2012). Algoritma Genetika merupakan suatu metode yang sangat populer saat ini

dan sering digunakan pada berbagai aplikasi bisnis, teknik maupun bidang lainnya. Biasanya algoritma genetika digunakan untuk mendapatkan solusi optimal dari persoalan optimasi (minimisasi atau maksimasi) yang mempunyai banyak solusi yang mungkin (*feasible solution*). Meskipun algoritma genetika tidak menjamin bahwa selalu menghasilkan solusi optimal dari persoalan-persoalan optimasi. Akan tetapi, Algoritma Genetika pada umumnya mampu menghasilkan solusi yang baik setelah melewati proses evolusi (Admi Syarif, 2014).

Algoritma Genetika menjadi solusi penyelesaian persoalan optimasi karena mempunyai tiga manfaat sebagai berikut:

1. Algoritma Genetika tidak membutuhkan wawasan tentang persoalan matematika yang sulit. Dapat menyelesaikan permasalahan yang mempunyai fungsi tujuan dan beberapa permasalahan dengan pembatas (*constraint*) linear, nonlinear, diskrit, kontinu ataupun gabungan diantaranya.
2. Metode Algoritma Genetika umumnya memroses pencarian lokal terhadap solusi optimal yang terdekat. Oleh karena itu, seringkali solusi yang diperoleh tidak dapat menjamin solusi global


optimal. Suatu solusi baru dapat menjamin solusi global optimal dengan menggunakan metode Algoritma Genetika apabila permasalahan yang dihadapi memiliki properti *convex* dimana setiap lokal solusi optimal dari persoalan juga merupakan solusi global optimal.

3. Algoritma Genetika membagikan fleksibilitas untuk menggabungkan dengan metode lain (*hybrid*).

Melihat perbedaan terhadap metode-metode lainnya, Algoritma Genetika memroses pencarian terhadap solusi optimal dengan menggunakan empat cara sebagai berikut (Goldberg, 1989):

1. Algoritma Genetika melakukan pekerjaannya dengan proses coding dari parameter.
2. Algoritma Genetika memroses pencarian dengan menggunakan sekumpulan kromosom.
3. Algoritma Genetika memanfaatkan informasi dari fungsi tujuan bukan menggunakan fungsi turunan atau sejenisnya.
4. Algoritma Genetika menggunakan aturan probabilitas.

Algoritma Genetika mempunyai siklus yang pertama kali dikenalkan oleh David Goldberg yang ditunjukkan pada gambar 2.2



Gambar 2.2 Siklus Algoritma Genetika

(Jadav Kinjal, 2012)

2.5.1. Struktur Algoritma Genetika

Proses penurunan gen ditiru oleh operasi Algoritma Genetika ketika melakukan proses gevaluasi untuk memperoleh hasil *offspring* pada setiap generasi. Hal ini menyebabkan operasi evaluasi meniru proses dari evaluasi Darwin (*Darwin Evolution*) untuk menghasilkan suatu populasi dari satu generasi ke generasi selanjutnya. Algoritma Genetika mempunyai beberapa struktur yang dapat ditunjukkan sebagai berikut (Berlianty, 2010):

1. Teknik Pengkodean

Penerapan teknik pengkodean dengan cara mengkodekan gen dari kromosom, dimana gen tersebut bagian dari kromosom. Satu variabel pada umumnya diwakili oleh satu gen. Algoritma genetika akan memproses

dengan solusi alternatif yaitu harus dikodekan terlebih dahulu kedalam bentuk kromosom. Berdasarkan atas jenis simbol yang akan digunakan oleh suatu nilai gen, maka model pengkodean ini dapat digolongkan sebagai berikut (Desiani, 2006):

a. Pengkodean Biner

Model pengkodean paling umum digunakan, yaitu pengkodean biner. Karena pengkodean ini pertama kali digunakan pada metode Algoritma Genetika oleh *Holland*. Pengkodean biner mempunyai keuntungan ialah proses menciptakannya sederhana dan mudah dimanipulasi. Pengkodean biner dapat membagikan kemungkinan-kemungkinan untuk kromosom meskipun dengan jumlah nilai-nilai yang terjadi pada suatu gen yang sedikit (0 dan 1) (Desiani, 2006).

b. Pengkodean Bilangan Riil

Pengkodean bilangan riil merupakan suatu pengkodean bilangan yang

terbentuk riil. Pengkodean riil mampu menyelesaikan kendala dengan tepat serta mengatasi permasalahan dari optimalisasi fungsi. Hal ini menyebabkan struktur topologi ruang genotif untuk pengkodean bilangan riil identik dengan ruangan fenotifnya. Oleh karena itu, operator genetika dapat terbentuk secara efektif dengan menggunakan teknik yang digunakan yang berasal dari suatu metode konvensional. (Desiani, 2006).

c. Pengkodean Bilangan Bulat

Suatu model yang mengkodekan bilangan kedalam bentuk bilangan bulat. Pengkodean ini cocok untuk digunakan pada masalah optimasi kombinatorial.

d. Pengkodean Struktur Data

Pengkodean struktur data merupakan suatu model pengkodean yang menggunakan struktur data. Pengkodean ini digunakan untuk masalah kehidupan yang lebih kompleks.

2. Individu

Individu mempunyai pengertian mirip dengan kromosom yang merupakan kumpulan gen. Dalam menyelesaikan permasalahan dengan menggunakan Algoritma Genetika perlu memperhatikan beberapa istilah penting. Istilah-istilah tersebut dapat diklasifikasikan sebagai berikut (Berlianty, 2010):

- a. Kromosom, yaitu tempat penyimpanan informasi genetika. biasanya *string* disesuaikan sebagai kromosom di dalam Algoritma Genetika.
- b. *Genotype* (struktur), yaitu fungsi kerja dari suatu organisme yang terbentuk dari kombinasi satu atau beberapa kromosom.
- c. *Phenotype* (set parameter), yaitu proses transformasi kode-kode genetika mengakibatkan interaksi di dalam struktur.
- d. *Genes*, yaitu suatu kromosom yang terbentuk oleh beberapa gen.

- e. *Alleles (feature value)*, yaitu suatu fitur yang mempunyai nilai fitur tertentu.
- f. *Locus (positioning)*, yaitu letak suatu gen di dalam kromosom. Setiap fitur mempunyai urutan posisi di dalam *string*.

3. Membangkitkan Populasi Awal

Sebuah proses yang membangkitkan sejumlah individu secara acak atau melalui prosedur tertentu merupakan proses dari membangkitkan populasi awal. Suatu populasi mempunyai ukuran yang tergantung pada masalah yang akan diselesaikan serta jenis operator genetika yang akan diterapkan. Pembangkitan populasi awal dapat dilakukan apabila ukuran dari populasi tersebut telah ditentukan. Dalam pembangkitan populasi awal mempunyai beberapa teknik diantaranya sebagai berikut (Syarif, 2014):

- a. Metode *Random Search* merupakan suatu metode yang melakukan pencarian solusi dimulai dari suatu titik uji tertentu. Titik uji tersebut dapat dikatakan sebagai

solusi alternatif yang disebut sebagai populasi.

- b. *Random Generator* merupakan teknik yang menjadikan pembangkitan bilangan random terlibat untuk nilai setiap gen yang sesuai dengan representasi kromosom yang digunakan.
- c. Pendekatan tertentu merupakan suatu gen dari populasi awal yang terbentuk dari pendekatan dengan memasukkan nilai tertentu.
- d. Permutasi Gen merupakan permutasi Josephus yang digunakan dalam permasalahan kombinatorial seperti TSP. *Travelling Salesman Problem* (TSP) merupakan seorang *salesman* harus mengunjungi sejumlah N kota dan setiap kota hanya dikunjungi sekali agar dapat menyelesaikan permasalahan umum dalam optimasi kombinatorial. *Salesman* wajib memilih rute perjalanan sehingga jarak total yang *salesman* tempuh minimum (Budi Santosa, 2017).


4. Fungsi *Fitness*

Suatu fungsi yang digunakan untuk menghitung nilai kesamaan atau derajat optimasi suatu kromosom merupakan *fitness function* (fungsi *fitness*). Nilai yang diperoleh dari fungsi *fitness* menunjukkan seberapa optimal solusi yang diperoleh (Zukhri, 2014).

5. Seleksi

Populasi yang mempunyai kromosom di dalamnya akan melalui proses seleksi untuk dipilih menjadi orang tua. Kromosom yang baik akan bertahan dan menghasilkan keturunan yang baru untuk generasi berikutnya sesuai teori Evolusi Darwin. Pada umumnya proses seleksi ini dilakukan secara proporsional sesuai dengan nilai *fitnessnya*. Biasanya yang digunakan pada suatu metode seleksi adalah *roulette-wheel* (roda rolet). Metode ini meniru gaya permainan *roulette-wheel* yang mana masing-masing kromosom menempati potongan lingkaran pada roda rolet secara proporsional sesuai dengan nilai *fitnessnya*.

Nilai *fitness* lebih besar yang dihasilkan kromosom akan menempati potongan lingkaran yang lebih besar, berbeda dengan kromosom yang mempunyai nilai *fitness* rendah (Suyanto, 2005).



Gambar 2.3 Contoh penggunaan metode *roulette-wheel selection*. K2 dengan nilai *fitness* paling besar menempati potongan sebesar setengah lingkaran. Oleh karena itu, K2 mempunyai peluang sebesar 0,5 (2 dibagi 4) untuk terpilih sebagai orang tua.


6. *Crossover* atau Pindah Silang

Proses *Crossover* atau pindah silang adalah salah satu struktur penting dalam algoritma genetika. Pindah silang merupakan proses operasi yang

menggabungkan dua kromosom orang tua menjadi kromosom baru (*offspring*). Ukuran populasi yang sangat kecil akan mengakibatkan pindah silang menjadi buruk. Di dalam populasi yang sangat kecil, suatu kromosom yang menuju ke solusi akan cepat membagikan ke kromosom-kromosom lainnya. Dalam menyelesaikan masalah tersebut menggunakan aturan bahwa pindah silang hanya dapat dilakukan dengan suatu probabilitas tertentu p_c . *Crossover* dapat dioperasikan hanya jika suatu bilangan random $[0,1]$ dibangkitkan kurang dari p_c yang telah ditentukan dan biasanya p_c diset mendekati 1 (Suyanto, 2005).


Pindah silang (*Crossover*) mampu diimplementasikan dengan cara yang berbeda-beda. Adapun cara paling sederhana yaitu pindah silang satu titik potong (*one-point crossover*). Posisi penyilangan k ($k = 1, 2, 3, \dots, N-1$) dengan N panjang kromosom diseleksi secara random. Variabel-variabel diganti antar kromosom

pada titik tersebut untuk menghasilkan anak (Kusumadewi, 2005).



Gambar 2.4 Pindah silang satu titik potong
(Suyanto, 2005)

Adapun cara kedua yaitu penyilangan banyak titik (*Multipoint crossover*). Posisi penyilangan k_i ($k_i = 1, 2, 3, \dots, N-1$), ($i = 1, 2, 3, \dots, m$) dimana m adalah banyaknya jumlah titik silang dan N panjang kromosom diseleksi secara random. Posisi titik silang dilarang pada posisi yang sama serta diurutkan naik.



Gambar 2.5 Pindah silang banyak titik
(Kusumadewi, 2005)

Cara ketiga yaitu dengan penyalangan seragam (*Uniform crossover*). Metode ini mempunyai potensi sebagai tempat penyalangan di setiap lokasi. Suatu induk akan memberikan bit ke anak yang dipilih secara random dengan peluang yang sama. Disini Anak-1 akan dihasilkan dari Induk-1 jika bit *mask* bernilai 1 dan dari Induk-2 jika bit *mask* bernilai 0. Sedangkan Anak-2 akan diperoleh hasilnya dari kebalikan *mask* (Kusumadewi, 2005).

Orang tua 1	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	
Orang tua 2	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
	g^1										g^{20}									
Mask bit	1	1	1	0	0	0	0	1	1	1	0	0	0	0	0	0	1	1	1	
Anak 1	0	0	0	0	0	0	0	1	1	1	0	0	0	0	0	0	1	1	1	
Anak 2	1	1	1	1	1	1	1	0	0	0	1	1	1	1	1	0	0	0	1	
	g^1										g^{20}									


Gambar 2.6 Pindah silang seragam
(Chipperfield, 2005)

7. Mutasi

Presentasi dari jumlah keseluruhan gen yang terdapat pada suatu populasi yang telah bermutasi dapat diartikan menjadi peluang mutasi (P_m). Banyak gen yang tidak pernah dievaluasi karena mungkin berguna jika peluang mutasi lebih kecil. Namun, jika peluang mutasi lebih besar maka akan terlalu banyak gangguan acak yang mengakibatkan anak akan kehilangan kecocokan dari induknya dan algoritma akan kehilangan kemampuan untuk mempelajari histori pencarian (Kusumadewi, 2005).

Secara random mutasi dapat dilakukan berdasarkan aturan dan nilai peluang mutasi. Peluang mutasi (P_m) diatur sebesar

$1/n$, dimana n adalah jumlah gen yang terdapat pada kromosom. Sebagai contoh, nilai gen g_{10} akan berubah apabila nilai dari bilangan random yang diperoleh lebih kecil dari peluang mutasi yang berlaku pada gen g_{10} (Suyanto, 2005).



Gambar 2.7 Mutasi satu gen (Suyanto, 2005)

8. Kondisi Selesai atau Penggantian Populasi

Algoritma Genetika akan menghentikan proses pencariannya jika kondisinya telah terpenuhi. Namun, jika kondisinya belum terpenuhi maka Algoritma Genetika akan mengulangi lagi prosesnya dengan kembali ke proses evaluasi *fitness*. Dalam Algoritma Genetika ada yang disebut dengan skema penggantian populasi atau *generational replacement*, artinya bahwa semua individu dari suatu generasi diganti oleh N individu atau populasi baru hasil pindah silang

(*Crossover*) dan mutasi. Siklus penggantian populasi yang paling ekstrem yaitu hanya dengan mengganti satu individu saja dalam setiap generasi yang disebut dengan *Steady-state reproduction* (Suyanto, 2005).

2.6. Kajian Pustaka

Menurut Nazir (2005) Kajian Pustaka merupakan suatu studi literatur yang berarti menjelajahi sumber data dari bahan sekunder yang bertujuan untuk menunjang penelitian dan meninjau ilmu yang terkait dengan penelitian yang berkembang serta kesimpulan yang pernah dibuat. Pada penelitian ini menggunakan kajian pustaka sebagai referensi untuk menjelajahi informasi dari penelitian-penelitian sebelumnya agar memperoleh teori-teori yang berkaitan dengan judul penelitian. Adapun penelitian-penelitian yang digunakan untuk menjadi referensi antara lain:

1. Penelitian yang dilakukan oleh Nur Azise, dkk. (2019) yang berjudul “Prediksi Pendapatan Penjualan Obat Menggunakan Metode *Backpropagation Neural Network* dengan Algoritma Genetika Sebagai Seleksi Fitur”. Penelitian ini dilakukan pada Rumah Sakit Swasta di Situbondo. Hasil dari penelitian tersebut menggunakan metode

- Backpropagation* menghasilkan nilai RMSE 0,152, sedangkan pada pengujian model *Backpropagation Neural Network* dengan menggunakan algoritma genetika sebagai seleksi fitur menghasilkan nilai RMSE 0,115 dengan fitur terseleksi menjadi 10 fitur.
2. Penelitian yang dilakukan oleh Fajriyanto, dkk. (2017) yang berjudul “Optimasi Prediksi Tingkat Produksi Bawang Merah Nasional Menggunakan Metode *Backpropagation Neural Network* Berbasis Algoritma Genetika”. Penelitian ini menggunakan data pada produksi bawang merah yang ada pada Badan Pusat Statistik (BPS). Pada penelitian ini, penulis mengimplementasikan metodenya terhadap prediksi tingkat produksi bawang merah dengan memperoleh hasil dari metode *Backpropagation Neural Network* dan menghasilkan nilai RMSE 0,089, sedangkan jika menggunakan *Backpropagation Neural Network* dengan algoritma genetika menghasilkan nilai RMSE 0,062 dengan memboboti input fn1, fn2, fn3, dan fn4.
 3. Penelitian yang dilakukan oleh Eryanto Shaputra, dkk. (2021) yang berjudul “Prediksi Pendapatan Asli Daerah (PAD) Kabupaten Langkat Menggunakan Metode *Backpropagation Neural*

Network". Penelitian ini dilakukan pada pendapatan di Kabupaten Langkat, Sumatera Utara. Sistem *neural network* mengenali data-data latih dan data target dengan iterasi 488 target *error* 0,5 dan *learning rate* 0,1 sehingga menghasilkan prediksi jumlah PAD pada tahun 2020, yaitu sebesar Rp. 140.948.000.000.

4. Penelitian yang dilakukan oleh Welnof Satria (2020) yang berjudul "Jaringan Syaraf Tiruan *Backpropagation* untuk Peramalan Penjualan Produk (Studi Kasus di Metro Electronic dan Furniture)". Penelitian ini dilakukan di toko Metro Electronic dan Furniture yang berada di Sungai Penuh, Jambi. Peramalan penjualan produk ini sudah dirancang sesuai dengan arsitektur dan algoritma *backpropagation* pada *neural network*, sistem ini sudah berhasil membandingkan grafik data yang sebenarnya dengan hasil peramalan.
5. Penelitian yang dilakukan oleh Dwi Agung Wibowo (2018) yang berjudul "Prediksi Penjualan Obat Herbal Hp Pro Menggunakan Algoritma *Neural Network*". Penelitian ini dilakukan pada PT. Mitra Barito Simber Sejahtera. Tujuan dari penelitian ini adalah menghasilkan sebuah akurasi data untuk

prediksi penjualan dengan memakai metode *neural network* berdasarkan data-data yang terdahulu.

6. Penelitian yang dilakukan oleh Holpan Torang B Tambunan, dkk. (2021) yang berjudul “Implementasi Jaringan Syaraf Tiruan (JST) untuk Memprediksi Jumlah Penjualan Gas 3Kg Menggunakan Metode *Backpropagation*”. Penelitian ini dilakukan di pangkalan resmi yang berada di Pematangsiantar, Sumatera Utara. Data ini diperoleh dari 10 UD. di Pematangsiantar selama 4 tahun terakhir (2015-2017). Dengan melakukan improvisasi *learning rate* menggunakan 5 model: 2-10-1, 2-15-1, 2-20-1, 2-25-1, dan 2-30-1 diperoleh model arsitektur terbaik adalah 2-20-1 dengan tingkat akurasi 90% MSE *training* 0,0010000150, MSE Pengujian 0,0263081322 dan 1366. Dari serangkaian uji coba model, menambahkan *learning rate* pada kasus prediksi penjualan Gas 3 Kg di 10 UD. Pematangsiantar.

BAB III

METODE PENELITIAN

3.1. Jenis Penelitian

Penelitian ini menggunakan jenis penelitian kuantitatif. Penelitian kuantitatif merupakan penelitian yang menghasilkan beberapa penemuan yang dapat dicapai atau diraih dengan menggunakan prosedur-prosedur statistik atau cara lain dari kuantifikasi. Teknik dari penelitian kuantitatif menggunakan angka-angka, pengumpulan informasi, dan penyajian hasil. Dengan menggabungkan faktor pencarian yang memperhatikan perkembangan terkini yang terjadi di masa sekarang sebagai bentuk pencarian (Jayusman, 2020).

3.2. Sumber Data

Sumber data yang digunakan dalam penelitian ini adalah data sekunder. Data sekunder merupakan data primer yang telah diproses atau data yang telah diberikan oleh pihak data primer atau pihak lain. Data primer menunjukkan tabel-tabel ataupun diagram-diagram (Abdullah, 2015). Sumber data yang akan digunakan dalam penelitian ini adalah dokumentasi yang bersumber dari JNE Express Sekaran tahun 2019-2021 sebanyak 33 data.

3.3. Metode Pengumpulan Data

Metode pengumpulan data dalam penelitian ini adalah dengan cara pengambilan data atau dokumentasi. Telaah dokumentasi merupakan suatu cara yang digunakan untuk menemukan data atau informasi yang dibutuhkan dalam penelitian. Meskipun data yang diperoleh merupakan data sekunder, akan tetapi data tersebut masih memiliki arti penting dan dapat digunakan dalam penelitian (Abdullah, 2015). Dokumen atau data yang digunakan dalam penelitian ini adalah data pendapatan agen ekspedisi pengiriman barang, yaitu JNE Express Sekaran, GunungPati, Kota Semarang.

Tabel 3.1 Data Pendapatan Bulanan JNE Express
Sekaran

Bulan	Pendapatan
Januari 2019	24361000
Februari 2019	21801500
Maret 2019	23949500
April 2019	35972500
Mei 2019	53290394
...	...
September 2021	22866000

3.4. Metode Analisis Data

Metode analisis data yang digunakan dalam penelitian ini menggunakan metode *backpropagation artificial neural network* dan algoritma genetika dengan menggunakan *software Matlab*. Langkah-langkah untuk menganalisis data dengan menggunakan metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika adalah sebagai berikut:

1. *Backpropagation Artificial Neural Network*

- a. Menyiapkan data yang akan digunakan untuk penelitian, yaitu data pendapatan bulanan JNE Express tahun 2019-2021 sebanyak 33 data.
- b. Menentukan struktur dan membentuk jaringan (*hidden layer*, pola *input* dan *output*).
- c. Melakukan transformasi data ke dalam sigmoid biner. Sigmoid biner berarti bahwa nilai dari fungsi asimtotik tidak pernah mencapai angka 0 atau 1.
- d. Melakukan pembagian data. Penelitian ini data yang akan dibagi menjadi data *training* dan data *testing* adalah 80% untuk data *training* dan 20% untuk data *testing*.


- e. Melakukan inisialisasi parameter dengan menentukan nilai *goal*, *learning rate*, *epoch*, dan *gradient*.
- f. Melakukan proses *training* dan *testing*.
- g. Pemilihan arsitektur jaringan terbaik berdasarkan MSE, RMSE, dan MAPE terkecil.



Gambar 3.1 *Flowchart Backpropagation Artificial Neural Network*

2. Algoritma Genetika

- a. Menyiapkan data yang akan digunakan untuk penelitian, yaitu data pendapatan bulanan JNE Express tahun 2019-2021 sebanyak 33 data.
- b. Melakukan pemrosesan data yang telah disiapkan dan diinput.
- c. Pembangkitan ukuran populasi atau populasi akan dilakukan.
- d. Melakukan evaluasi nilai *fitness* agar mencapai nilai yang maksimum. Apabila sudah mencapai nilai maksimum maka akan mendapatkan nilai MSE terkecil dan dapat diprediksi dengan menggunakan *feedforward*. Akan tetapi, jika nilai *fitness* belum mencapai nilai maksimum maka akan berlanjut pada tahap seleksi.
- e. Menyeleksi dengan model *Roulette-Wheel*.
- f. Melakukan PindahSilang atau disebut juga dengan *Crossover*.
- g. Melakukan mutasi dan akan terbentuk menjadi populasi baru. Selanjutnya cek kembali pada evaluasi *fitness* untuk mengetahui bahwa nilai *fitness* sudah mencapai maksimum atau belum.



Gambar 3.2 *Flowchart* Algoritma Genetika

BAB IV


HASIL PENELITIAN DAN PEMBAHASAN

4.1. Deskripsi Data

Data yang digunakan merupakan data pendapatan bulanan dari agen ekspedisi pengiriman barang, yaitu JNE Express Sekaran yang terdiri dari 33 data dimulai pada tahun 2019-2021. Berikut data pendapatan JNE Express Sekaran:

Tabel 4.1 Data Pendapatan JNE Express Sekaran

Bulan	Pendapatan
Januari 2019	24361000
Februari 2019	21801500
...	...
September 2021	22866000



Gambar 4.1 Grafik Data Pendapatan JNE Express Sekaran

4.2. Implementasi Metode *Backpropagation Artificial Neural Network*

Dalam melakukan penelitian terhadap estimasi data pendapatan, adapun langkah-langkah yang digunakan dalam mengimplementasikan *Backpropagation Artificial Neural Network* agar mendapatkan model terbaik yaitu: menyiapkan data, menentukan pola *input* dan *output*, transformasi data, transpose data, pembagian data, inisialisasi parameter, proses *training* dan *testing*, menghitung nilai MSE, RMSE, dan MAPE.

Implementasi metode *Backpropagation Neural Network* dan Algoritma Genetika menggunakan *software MatLab*.

4.2.1. Pola *Input* dan *Output*

Pola *input* dan *output* digunakan untuk menentukan pembagian data antara data *training* dan data *testing*. Berikut adalah pola *input* dan *output* yang digunakan dalam penelitian ini:

Tabel 4.2 Pola *Input* dan *Output*

No	Input	Output
1	X_1, X_2, X_3, X_4	Y_1
2	X_2, X_3, X_4, X_5	Y_2
3	X_3, X_4, X_5, X_6	Y_3
...	...	...
32	$X_{32}, X_{33}, X_{34}, X_{35}$	Y_{32}

Pola yang digunakan pada tabel 4.2 untuk meramalkan T_{+1} *input* adalah $T_{-3}, T_{-2}, T_{-1}, T_0$. Nilai X merupakan jumlah data yang akan digunakan sebagai pola *input* dimana $X_i, i = 1, 2, 3, \dots, n$. Sedangkan nilai Y merupakan nilai target yang akan digunakan pada metode *Backpropagation Artificial Neural Network* dalam proses *training* dan *testing*.

4.2.2. Transformasi Data

Fungsi sigmoid mempunyai nilai maksimum = 1, maka pola yang targetnya mempunyai nilai lebih besar daripada 1, pola *input* dan *output* harus ditransformasikan dahulu sehingga semua polanya mempunyai range yang sama dengan fungsi sigmoid yang dipakai. Data pendapatan dapat ditransformasikan atau

dinormalisasikan dengan menggunakan rumus persamaan 2.10 atau metode *min-max*:

$$X' = \frac{0,8(x - a)}{b - a} + 0,1$$

Data dapat ditransformasikan atau dinormalisasikan ke interval (0,1). Namun, akan lebih baik apabila data ditransformasikan atau dinormalisasikan ke interval yang lebih kecil, misalnya pada interval (0.1, 0.9). Transformasi atau normalisasi data bertujuan untuk mengubah skala data asli menjadi skala data yang mempunyai nilai sama yang menjadikan pemrosesan data lebih efisien.

Tabel 4.3 Transformasi Data

	NORMALISASI				
	X ₁	X ₂	X ₃	X ₄	Y
1	0.1404	0.1000	0.1339	0.3236	0.5969
2	0.1000	0.1339	0.3236	0.5969	0.3286
3	0.1339	0.3236	0.5969	0.3286	0.5701
...	...	...	...	...	...
32	0.4613	0.1168	-0.2441	-0.2441	-0.2441

$$X'_1 = \frac{0.8(24361000 - 21801500)}{72494000 - 21801500} + 0,1$$

$$= 0.1404$$

$$X'_2 = \frac{0.8(21801500 - 21801500)}{72494000 - 21801500} + 0,1$$

$$= 0.1000$$

$$X'_3 = \frac{0.8(23949500 - 21801500)}{72494000 - 21801500} + 0,1$$

$$= 0.1339$$

⋮

$$X'_{32} = \frac{0.8(0 - 21801500)}{72494000 - 21801500} + 0,1$$

$$= -0.2441$$

4.2.3. *Transpose Data*

Setelah data ditransformasikan atau dinormalisasikan maka langkah selanjutnya adalah membuat tabel pola X_1 , X_2 , X_3 , X_4 , dan Y dimana X_1 - X_4 adalah *input* dan Y adalah *output*. Kemudian transpose data yang telah dibuat dari pola *input* dan *output* sebagai berikut:

Tabel 4.4 *Transpose Data*

	1	2	3	...	32
X_1	0.1404	0.1000	0.1339	...	0.4613
X_2	0.1000	0.1339	0.3236	...	0.1168
X_3	0.1339	0.3236	0.5969	...	-0.2441
X_4	0.3236	0.5969	0.3286	...	-0.2441
Y	0.5969	0.3286	0.5701	...	-0.2441

Transpose data digunakan untuk mengubah baris menjadi kolom dan kolom menjadi baris yang akan dimasukkan ke dalam *workspace*

variabel pada aplikasi *matlab* untuk dilakukan proses *training* dan *testing*.

4.2.4. Pembagian Data

Pembagian data ini digunakan untuk menentukan data *training* dan data *testing*. Total pola yang terbentuk ada 32 pola dari 33 data. Data akan dibagi menjadi 2 bagian, yaitu 80% data *training* (pola 1-25) dan 20% data *testing* (pola 26-32). Tujuan dari pembagian data adalah untuk mendapatkan keseimbangan antara pengenalan pola *training* secara benar dan respon yang baik untuk pola lain yang sejenis atau disebut juga dengan pola *testing*. Umumnya pembagian data yang sering digunakan pada penelitian yaitu 80% untuk data *training* dan 20% untuk data *testing*.

4.2.5. Inisialisasi Parameter

Dalam menginisialisasi parameter ini untuk menentukan nilai *goal*, *learning rate*, *epoch*, dan *gradient* dimana akan digunakan untuk melakukan proses *training* dan *testing*. Berikut adalah tabel dari parameter-parameter yang digunakan:

Tabel 4.5 Parameter Penelitian

Parameter	Nilai
<i>Epoch</i>	5000
<i>Goal</i>	0.001
<i>Gradient</i>	0.00001
<i>Learning Rate</i>	0.01

Epoch merupakan parameter yang menentukan jumlah iterasi maksimum. *Goal* merupakan parameter yang menentukan batas *error* atau kesalahan yang ingin diraih. *Gradient* merupakan parameter yang menentukan batas *gradient* minimum yang dicapai pada *training*. Sedangkan *Learning Rate* merupakan parameter yang menentukan konstanta belajar jaringan.

4.2.6. Implementasi Proses Training dan Testing *Backpropagation Artificial Neural Network*

Langkah pertama sebelum melakukan proses *training* dan *testing* metode *Backpropagation Artificial Neural Network*, yaitu membentuk arsitektur jaringan. Dibentuknya arsitektur jaringan agar mendapatkan model terbaiknya yang akan menghasilkan nilai *error* terkecil dan akurat.

Pada tabel 4.6 menunjukkan karakteristik arsitektur jaringan sebagai berikut:

Tabel 4.6 Karakteristik Arsitektur Jaringan


Karakteristik	Spesifikasi
<i>Hidden Layer</i>	1
<i>Hidden Neuron</i>	10, 11, 12
<i>Input Data</i>	4
<i>Output Data</i>	1
<i>Training Function</i>	<i>Traingdx</i>
<i>Adaption Learning Function</i>	<i>Learngdm</i>
<i>Goal</i>	0.001
<i>Epoch</i>	5000
<i>Learning Rate</i>	0.01

Hidden Neuron merupakan neuron tersembunyi bagian dari *hidden layer*. Jumlah neuron digunakan untuk membentuk model arsitektur jaringan dan menentukan nilai MSE terkecil. Sesuai dengan ketentuan atau aturan yang dipakai menurut Jeff Heaton (2008) yang mengatakan bahwa jumlah neuron dari *hidden layer* sebaiknya 2 atau 3 lebih besar dari jumlah pola *input* ditambah dengan jumlah pola *output*, maka penelitian ini menggunakan jumlah neuron 10, 11, dan 12 yang bertujuan untuk


membandingkan antara ketiga jumlah neuron mana yang mendapatkan model terbaik arsitektur jaringan dan menghasilkan nilai MSE terkecil. Jenis *training function* dan *adaption learning function* penelitian ini adalah *traingdx* dan *learnngdm*. *Traingdx* yaitu mengkombinasikan pembelajaran adaptif *learning rate* dengan penambahan momentum, sedangkan *learnngdm* yaitu penurunan gradien dengan bobot momentum dan fungsi pembelajaran bias. Berikut proses *training* dan *testing* dari model arsitektur 4-10-1, 4-11-1, dan 4-12-1:

a. *Training* dan *Testing* Arsitektur 4-10-1


Data pendapatan bulanan JNE Express Sekaran tahun 2019-2021 terdiri 33 data dan terbagi menjadi 32 pola. Pada gambar 4.2 menunjukkan struktur *Neural Network* secara umum dan gambar 4.3 menunjukkan struktur *Neural Network* menggunakan *software matlab*. Berikut adalah hasil *training* dan *testing* dengan model atau pola arsitektur 4-10-1.



Gambar 4.2 Struktur *Neural Network*
Arsitektur 4-10-1 Secara Umum



Gambar 4.3 *Nntraintool* Arsitektur 4-10-1



Gambar 4.4 Plotregression Arsitektur 4-10-1

Berdasarkan gambar 4.4 menunjukkan bahwa *input layer* 4, *hidden neuron* 10, dan *output layer* 1 sehingga *epoch* atau iterasi berhenti pada 487 dengan waktu *training* = 1 detik dan *error* < *goal* = 0.000994 < 0.001, nilai *error performance* jaringan lebih baik daripada *goal* yang telah ditentukan. Gambar plotregression menunjukkan garis berwarna sudah sejajar dengan garis putus-putus menandakan bahwa kinerja jaringan sudah mencapai best atau terbaiknya. Setelah data selesai melakukan *training*,

maka selanjutnya adalah proses *testing* dan menghasilkan data sebagai berikut.

Tabel 4.7 Hasil *Training* Arsitektur 4-10-1

TRAINING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.5969	0.6010	-0.0041	1.714E-05	0.006936
0.3286	0.3156	0.0130	0.000168	0.03944
0.5701	0.5122	0.0579	0.0033547	0.101596
...	...	...	...	...
0.2902	0.2387	0.0515	0.0026512	0.177429
Total			0.0946507	
MSE			0.003786	
MAPE				0.103933

Tabel 4.8 Hasil *Testing* Arsitektur 4-10-1


TESTING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.3338	0.4507	-0.1169	0.0137	0.35021
0.6591	0.6628	-0.0037	0.000014	0.005599
0.4613	0.3223	0.1390	0.0193	0.301387
...	...	...	...	...
-0.2441	0.5537	-0.7978	0.6365	3.268497
Total			1.0556	
MSE			0.150807	
MAPE				1.410939

Berdasarkan hasil data *training* dan *testing* memperoleh MSE *training* sebesar 0.003786, MAPE sebesar 0.104%, dan RMSE sebesar 0.06153, sedangkan MSE *testing* sebesar 0.150807, MAPE sebesar 1.41%, dan RMSE sebesar 0.3883.


Nilai MSE dan RMSE sudah mendekati nol yang mana model tersebut menghasilkan nilai yang akurat untuk digunakan dalam *testing*. Nilai MAPE yang telah diperoleh dari hasil *testing* mempunyai nilai yang kurang dari 10%, artinya kemampuan model peramalan ini sangat baik.

b. *Training* dan *Testing* Arsitektur 4-11-1


Data pendapatan bulanan JNE Express Sekaran tahun 2019-2021 terdiri 33 data dan terbagi menjadi 32 pola. Pada gambar 4.5 menunjukkan struktur *Neural Network* secara umum dan gambar 4.6 menunjukkan struktur *Neural Network* menggunakan *software matlab*. Berikut adalah hasil *training* dan *testing* dengan model atau pola arsitektur 4-11-1.



Gambar 4.5 Struktur *Neural Network* Arsitektur 4-11-1 Secara Umum



Gambar 4.6 *Nntraintool* Arsitektur 4-11-1



Gambar 4.7 Plotregression Arsitektur 4-11-1

Berdasarkan gambar 4.7 menunjukkan bahwa *input layer* 4, *hidden neuron* 11, dan *output layer* 1 sehingga *epoch* atau iterasi berhenti pada 168 dengan waktu *training* = 1 detik dan *error* < *goal* = 0.000990 < 0.001, nilai *performance error* jaringan lebih baik daripada *goal* yang telah ditentukan. Gambar plotregression menunjukkan garis berwarna sudah sejajar dengan garis putus-putus menandakan bahwa kinerja jaringan sudah mencapai best atau terbaiknya.

Setelah data selesai melakukan *training*, maka selanjutnya adalah proses *testing* dan menghasilkan data sebagai berikut.

Tabel 4.9 Hasil *Training* Arsitektur 4-11-1

TRAINING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.5969	0.6045	-0.0076	5.74564E-05	0.01270
0.3286	0.3509	-0.0223	0.000495953	0.06777
0.5701	0.5700	0.0001	6.4E-09	0.00014
...	...	...	...	...
0.2902	0.2749	0.0153	0.00023409	0.05272
Total			0.084018405	
MSE			0.003360736	
MAPE				0.08983

Tabel 4.10 Hasil *Testing* Arsitektur 4-11-1


TESTING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.3338	0.5208	-0.1870	0.034969	0.56022
0.6591	0.7579	-0.0988	0.009765	0.14993
0.4613	0.3550	0.1064	0.01131	0.23054
...	...	...	...	...
-0.2441	0.75796	-1.0021	1.004124	4.10512
Total			1.475646	
MSE			0.210807	
MAPE				1.44254

Berdasarkan hasil data *training* dan *testing* memperoleh MSE *training* sebesar 0.003360736, MAPE sebesar 0.089%, dan RMSE sebesar 0.05797, sedangkan MSE *testing* sebesar 0.210807, MAPE sebesar 1.44%, dan RMSE sebesar 0.4591.


Nilai MSE dan RMSE sudah mendekati nol yang mana model tersebut menghasilkan nilai yang akurat untuk digunakan dalam *testing*. Nilai MAPE yang telah diperoleh dari hasil *testing* mempunyai nilai yang kurang dari 10%, artinya kemampuan model peramalan ini sangat baik.

c. *Training dan Testing* Arsitektur 4-12-1


Data pendapatan bulanan JNE Express Sekaran tahun 2019-2021 terdiri 33 data dan terbagi menjadi 32 pola. Pada gambar 4.8 menunjukkan struktur *Neural Network* secara umum dan gambar 4.9 menunjukkan struktur *Neural Network* menggunakan *software matlab*. Berikut adalah hasil *training* dan *testing* dengan model atau pola arsitektur 4-12-1.



Gambar 4.8 Struktur *Neural Network* Arsitektur 4-12-1 Secara Umum



Gambar 4.9 *Nntraintool* Arsitektur 4-12-1



Gambar 4.10 *Plotregression* Arsitektur 4-12-1

Berdasarkan gambar 4.10 menunjukkan bahwa *input layer* 4, *hidden neuron* 12, dan *output layer* 1 sehingga *epoch* atau iterasi berhenti pada 261 dengan waktu *training* = 1 detik dan *error* < *goal* = 0.000996 < 0.001, nilai *performance error* jaringan lebih baik daripada *goal* yang telah ditentukan. Gambar *plotregression* menunjukkan garis berwarna sudah sejajar dengan garis putus-putus menandakan bahwa kinerja jaringan sudah mencapai best atau terbaiknya.

Setelah data selesai melakukan *training*, maka selanjutnya adalah proses *testing* dan menghasilkan data sebagai berikut.

Tabel 4.11 Hasil *Training* Arsitektur 4-12-1

TRAINING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.5969	0.5940	0.0029	8.1796E-06	0.00479
0.3286	0.3329	-0.0043	1.8404E-05	0.01306
0.5701	0.5521	0.0180	0.00032508	0.03163
...	...	...	...	...
0.2902	0.24435	0.0459	0.00210222	0.15799
Total			0.03609961	
MSE			0.00144398	
MAPE				0.06609

Tabel 4.12 Hasil *Testing* Arsitektur 4-12-1

TESTING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.3338	0.5423	-0.2085	0.043485	0.62472
0.6591	0.2739	0.3852	0.148371	0.58442
0.4613	0.5746	-0.1133	0.01283	0.24555
...	...	...	...	...
-0.2441	-0.10178	-0.1423	0.020255	0.58304
Total			1.114175	
MSE			0.159168	
MAPE				1.66229

Berdasarkan hasil data *training* dan *testing* memperoleh MSE *training* sebesar 0.00144398, MAPE sebesar 0.066%, dan RMSE sebesar 0.0379, sedangkan MSE *testing* sebesar 0.159168, MAPE sebesar 1.66%, dan RMSE sebesar 0.3989.

Nilai MSE dan RMSE sudah mendekati nol yang mana model tersebut menghasilkan nilai yang akurat untuk digunakan dalam *testing*. Nilai MAPE yang telah diperoleh dari hasil *testing* mempunyai nilai yang kurang dari 10%, artinya kemampuan model peramalan ini sangat baik.

d. Rekapitulasi Model

Dari hasil proses *training* dan *testing* yang telah dilakukan, diperoleh hasil penilaian model arsitektur terbaik yang dapat dilihat dari berbagai parameter seperti *epoch*, MSE, MAPE, dan RMSE. Pada tabel 4.13 menunjukkan rekapitulasi antara ketiga model sebagai berikut:

Tabel 4.13 Rekapitulasi Model

Model	<i>Epoch</i>	MSE	RMSE	MAPE
4-10-1	487	0.150807	0.3883	1.41%
4-11-1	168	0.210807	0.4591	1.44%
4-12-1	261	0.159168	0.3989	1.66%

Berdasarkan tabel 4.13 menunjukkan bahwa ketiga model tersebut, yaitu 4-10-1, 4-11-1, dan 4-12-1 mempunyai nilai error (MSE dan RMSE) terkecil mendekati nol dan nilai MAPE kurang dari 10% yang berarti kemampuan ketiga model tersebut sangat baik. Akan tetapi, dapat diketahui bahwa model arsitektur 4-10-1 menjadi model terbaik karena menghasilkan nilai *error* MSE terkecil dan nilai MAPE terkecil.

4.3. Implementasi Metode Algoritma Genetika


Dalam proses optimasi, Algoritma Genetika akan memanggil *function-function* berikut:

1. BangMatrixIT, yaitu fungsi yang membangkitkan *matrix input* dan *matrix target*.
2. InisialisasiPopulasi, yaitu fungsi yang membangkitkan jumlah populasi berupa *matrix* berukuran jumlah kromosom yang diinginkan x jumlah gen dalam sebuah kromosom.

3. DekodekanKromosom, yaitu fungsi yang melakukan proses *decoding* kromosom yang berisi bilangan biner menjadi individu yang berisi bilangan *real*.
4. BinaryEvalInd, yaitu fungsi yang bertujuan untuk mengevaluasi setiap individu yang berdasarkan fungsi *fitness*, sehingga dihasilkan nilai *fitness* setiap individu.
5. LinearFitnessRanking, yaitu fungsi ini bertujuan untuk mengurutkan individu berdasarkan nilai *fitnessnya* dari individu yang mempunyai *fitness* tertinggi sampai ke individu yang *fitnessnya* paling rendah. Nilai fitness diperoleh dari membagi tingkat kesalahan yang ingin dicapai.
6. RouletteWheel, yaitu fungsi yang digunakan untuk memilih kromosom yang akan melakukan operasi genetik atau pindahsilang dan mutasi.
7. PindahSilang, yaitu fungsi yang melakukan proses pindahsilang gen-gen antar kromosom induk.
8. Mutasi, yaitu fungsi yang melakukan proses pengubahan gen dalam kromosom.

Algoritma Genetika mencari nilai bobot dan bias yang optimal bagi jaringan *Feed Forward Neural Network* (FFNN) yang terdapat pada *function*

BinaryEvalInd untuk mendapatkan hasil nilai MSE yang paling kecil.



Gambar 4.11 AG BinaryEncoding

Pada gambar 4.11 menunjukkan bahwa Algoritma Genetika BinaryEncoding mencapai nilai *fitness* yang maksimum pada generasi ke-498 (hampir generasi ke-500), nilai *fitness* terbaik yang diperoleh yaitu $10209.027249 = 10209.02$ dan menghasilkan nilai MSE sebesar 0.000098 dan RMSE 0.001. Jika nilai *fitness* yang dihasilkan telah mencapai maksimumnya, maka tidak perlu dilakukan percobaan pada generasi baru lagi.

Nilai *fitness* yang maksimum menghasilkan nilai MSE terkecil yang menandakan bahwa *error* antara *output* jaringan dengan target semakin kecil. Nilai MSE


dihasilkan oleh jaringan yang mempunyai struktur bobot dan bias yang optimal.

FFNNterbaik =								
Columns 1 through 9								
9.8828	2.8516	9.1992	-2.3438	-1.6016	-1.5430	4.3359	1.3086	0.6445
Columns 10 through 16								
5.8789	-8.3398	4.5117	8.9258	-8.3789	-4.0234	0.1172		

Gambar 4.12 Struktur FFNN Terbaik

4.3.1. Pengujian Prediksi *FeedForward* Algoritma Genetika

Dengan menggunakan hasil *training* pada sistem Algoritma Genetika, nilai pendapatan akan di uji prediksi dengan *feed-forward neural network*. Hasil uji prediksi yang dibandingkan dengan data aktual atau data *real* pada gambar dan tabel berikut ini:



Gambar 4.13 Hasil Uji Prediksi

Pada gambar 4.13 menunjukkan bahwa ada beberapa data prediksi yang mengalami penurunan dibandingkan dengan data aktual,

akan tetapi data prediksi lebih banyak mengalami kenaikan dibandingkan dengan data aktual.

Berdasarkan gambar 4.13 diperoleh hasil prediksi yang dapat dibandingkan dengan data aktual yang telah diberikan, maka perbandingan data aktual dan hasil prediksi ditunjukkan pada tabel 4.14 sebagai berikut:

Tabel 4.14 Perbandingan Data Aktual dan Hasil Prediksi

Bulan	Data Aktual	Hasil Prediksi
Januari 2019	24361000	25292244
Februari 2019	21801500	22932430
Maret 2019	23949500	24911802
...	...	...
September 2021	22866000	23911640

Berdasarkan tabel 4.14 menunjukkan hasil perbandingan antara data aktual dan hasil prediksi pendapatan JNE Express Sekaran dan dapat diketahui bahwa hasil prediksi tidak jauh berbeda dengan data aktual yang telah diberikan. Setelah dihitung nilai MAPE pada tabel 4.14 diperoleh sebesar 0.012% dengan tingkat akurasi sebesar 99.98%.

4.4. Perbandingan Metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika

Proses *testing* pada metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika telah dilakukan, sehingga mendapatkan model-model terbaik sesuai dengan metodenya masing-masing. Hasil dari perbandingan dari kedua metode tersebut sebagai berikut:

Tabel 4.15 Hasil Perbandingan Metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika

Metode	MSE	RMSE
<i>Backpropagation Artificial Neural Network</i>	0.0359453	0.189
Algoritma Genetika	0.000098	0.001

Berdasarkan tabel 4.15 menunjukkan bahwa nilai RMSE secara keseluruhan dari data pendapatan JNE Express Sekaran dengan menggunakan metode *Backpropagation Artificial Neural Network* sebesar 0.189 dan Algoritma Genetika sebesar 0.001. Sehingga analisis hasil yang diperoleh menggunakan *Backpropagation Neural Network* dan Algoritma Genetika menunjukkan bahwa metode Algoritma Genetika lebih baik daripada metode *Backpropagation Artificial Neural Network*, karena memiliki nilai error atau nilai MSE dan RMSE terkecil.

Model terbaik yang dihasilkan oleh metode *Backpropagation Artificial Neural Network*, yaitu 4-10-1 dengan 4 sebagai *input layer*, 10 sebagai *hidden neuron*, dan 1 sebagai *output layer*. Sedangkan Algoritma Genetika mendapatkan hasil terbaiknya pada generasi ke-498 sehingga mendapatkan nilai *fitness* yang maksimum.

4.4.1. Hasil Prediksi Menggunakan *Testing Backpropagation Artificial Neural Network* dan Algoritma genetika

Setelah melakukan *testing* dan prediksi terhadap data pendapatan JNE Express Sekaran menggunakan metode *backpropagation artificial neural network* dan algoritma genetika, maka didapat hasil dari prediksi untuk bulan berikutnya pada tabel 4.16 sebagai berikut:

Tabel 4.16 Hasil Prediksi Pendapatan JNE Express Sekaran *Backpropagation Artificial Neural Network*

Bulan	Data Aktual	Hasil Prediksi
Oktober 2021	24582000	29428187
November 2021	20797000	26187669
Desember 2021	41207000	63493547

Berdasarkan tabel 4.16 menunjukkan hasil prediksi pendapatan JNE Express Sekaran pada bulan Oktober sampai Desember tahun 2021 dengan metode *Backpropagation Artificial Neural Network* yang diberikan data aktualnya. Hasil prediksi terlihat lebih besar daripada data aktualnya, dikarenakan ada kemungkinan beberapa faktor yang memengaruhi data aktualnya, seperti kualitas pelayanan, jumlah pengiriman barang, ataupun faktor lainnya.

Setelah dihitung nilai MAPE hasil prediksi pendapatan JNE Express Sekaran pada bulan Oktober sampai Desember tahun 2021 menggunakan metode *Backpropagation Artificial Neural Network* diperoleh sebesar 0.33% dengan tingkat akurasi sebesar 99.67%.

Sedangkan hasil prediksi pendapatan yang dihasilkan metode algoritma genetika didapat pada tabel 4.17 sebagai berikut:

Tabel 4.17 Hasil Prediksi Pendapatan JNE
Express Sekaran Algoritma Genetika

Bulan	Data Aktual	Hasil Prediksi
Oktober 2021	24582000	25011603
November 2021	20797000	20920021
Desember 2021	41207000	50553019

Berdasarkan tabel 4.17 menunjukkan hasil prediksi pendapatan JNE Express Sekaran pada bulan Oktober sampai Desember tahun 2021 dengan metode Algoritma Genetika yang diberikan data aktualnya. Hasil prediksi pada bulan Oktober dan November mendekati data aktualnya, sedangkan hasil prediksi bulan Desember terlihat lebih besar daripada data aktualnya dikarenakan ada kemungkinan beberapa faktor yang memengaruhi data aktualnya, seperti kualitas pelayanan, jumlah pengiriman barang, ataupun faktor lainnya.

Setelah dihitung nilai MAPE hasil prediksi pendapatan JNE Express Sekaran pada bulan Oktober sampai Desember tahun 2021 menggunakan metode Algoritma Genetika diperoleh sebesar 0.08% dengan tingkat akurasi sebesar 99.92%.

BAB V

SIMPULAN DAN SARAN

5.1. Simpulan

Berdasarkan hasil dari penelitian yang telah dilakukan, maka dapat ditarik kesimpulan dari hasil penelitian dan pembahasan terhadap estimasi pendapatan agen ekspedisi pengiriman barang JNE Express Sekaran, GunungPati, Kota Semarang dengan menggunakan metode *Backpropagation Artificial Neural Network* dan Algoritma Genetika adalah sebagai berikut:

1. Pada metode *Backpropagation Artificial Neural Network* diperoleh model aritektur terbaik, yaitu model 4-10-1. Artinya 4 sebagai *input layer*, 10 sebagai *hidden neuron*, dan 1 sebagai *output layer*. Parameter dari model ini antara lain, yaitu *learning rate* 0.01, *epoch* 487, dan *goal* 0.001 mampu menghasilkan nilai MSE sebesar 0.0359453, RMSE sebesar 0.189. Sedangkan untuk metode Algoritma Genetika mempunyai ukuran populasi 200, probabilitas pindah silang 0.8, probabilitas mutasi 0.03, generasi ke-498 mampu menghasilkan nilai *fitness* yang maksimum sebesar 10209.02, nilai MSE sebesar 0.000098 dan nilai RMSE 0.001.

2. Berdasarkan perbandingan hasil nilai MSE dan RMSE yang didapat pada *testing* masing-masing metode, Algoritma Genetika terbukti menghasilkan error atau nilai MSE dan RMSE terkecil dan terbaik sebesar 0.000098 dan 0.001 daripada metode *Backpropagation Artificial Neural Network*, serta mendapatkan hasil prediksi pendapatan pada bulan berikutnya, yaitu Oktober 2021 sebesar Rp 25,011,603.00, November 2021 sebesar Rp 20,920,021.00, dan Desember 2021 sebesar Rp 50,553,019.00.

5.2. Saran

Adapun saran yang dapat diberikan dalam penelitian ini agar menjadi lebih baik yaitu:

1. Untuk mengetahui hasil kinerja pada metode optimasi lainnya dapat menggunakan metode pembandingan dalam memprediksi, yaitu metode *Particle Swarm Optimization*, *Traveling Salesman Problem* (TSP), dan metode optimasi lainnya yang lebih akurat.
2. Pada penelitian ini hanya menggunakan data bulanan dari salah satu agen ekspedisi pengiriman barang di Kota Semarang. Oleh karena itu, untuk penelitian selanjutnya dapat menggunakan data

yang lebih besar dari beberapa ekspedisi pengiriman barang baik dari agen, cabang, maupun pusat.

DAFTAR PUSTAKA

- Abdullah, M. 2015. *Metode Penelitian Kuantitatif*. Yogyakarta: Aswaja Pressindo.
- Azise, N., Andono, P. N., & Pramunendar, R. A. (2019). Prediksi Pendapatan Penjualan Obat Menggunakan Metode Backpropagation Neural Network dengan Algoritma Genetika Sebagai Seleksi Fitur. *Jurnal Cyberku*, 15, 142–154.
<http://research.pps.dinus.ac.id/index.php/Cyberku/article/view/91>
- Berlianty, Intan, A. M. 2010. *Teknik-Teknik Optimasi Heuristik*. Yogyakarta: Graha Ilmu.
- Chatfield, C. 2000. *Time-Series Forecasting*. US: Chapman & Hall/CRC.
- Chipperfield, A., Fleming, P., Pohlheim, H., dan Fonseca, C. 2005. *Genetic Algorithm TOOLBOX For Use with MATLAB User's Guide Ver.1.2, Departement of Automatic Control and Systems Engineering, University of Sheffield*.
- Desiani, A., & Arhami, M. 2006. *Konsep Kecerdasan Buatan*. Yogyakarta: Andi Offset.
- Fauzan Haqiqi, Rahma Dewi Susanti, & Ferawati. (2020). Analisis Pengaruh Pemberian Modal Kerja Dan Biaya Produksi Terhadap Peningkatan Pendapatan Usaha Kecil Menengah Di Desa Pongkar Kecamatan Tebing

- Kabupaten Karimun (Tahun 2014 – 2018). *Jurnal Cafetaria*, 1(1), 63–72.
<https://doi.org/10.51742/akuntansi.v1i1.54>
- Goldberg, D. E. 1989. *Genetic Algorithm in Search Optimization and Machine Learning*. Addison Wesley Publishing Company, Incorporated, Reading, Massachusetts.
- Gufron, M., Ihsan, N., & Kholil, M. (2014). Analisa Peramalan Permintaan Produk Pipa PVC AW1 / 2 " SC 4M pada PT . W DJ. *Jurnal INTEGRA*, 4(1), 63–72.
- Harahap, R. M. (2017). Related Papers. *Over The Rim*, 191–199.
<https://doi.org/10.2307/j.ctt46nrzt.12>
- Heaton, Jeff. 2008. *Introduction of Neural Networks With Java 2nd Edition*. Heaton Research.
<https://quran.kemenag.go.id/surah/31>
<https://quranhadits.com/quran/31-luqman/luqman-ayat-34/>
- <https://www.jne.co.id/id/perusahaan/profil-perusahaan>
- Jayusman, I., & Shavab, O. A. K. 2020. Aktivitas Belajar Mahasiswa dengan Menggunakan Media Pembelajaran *Learning Management System (LMS)* Berbasis Edmodo Dalam Pembelajaran Sejarah. *Jurnal Artefak*, 7(1): 13.
- Kusuma, E. P., & Pratama, B. (2020). *Laporan Keuangan Pada PT Multipanel Intermitra Mandiri*. 1–19.
- Laksana, A. I. 2017. Perbandingan Metode Single Moving

- Average Smoothing dalam Pengembangan Sistem Peramalan Penjualan Mobil Baru, (6), 67-72.
- Makridakis S, Wheelwright SC, H. R. 2008. *1 / the Forecasting Perspective. Forecasting methods and applications.*
- Margi, Kristien. 2015. Analisa dan Penerapan Metode *Single Exponential Smoothing* Untuk Prediksi Penjualan Pada Periode Tertentu (Studi Kasus: PT. Media Cemara Kreasi). Jakarta: Universitas Bunda Mulia.
- Montgomey, D. C., Jennings, C. L., & Kulahci, M. 2008. *Introduction to Time Series Analysis and Forecasting. Journal of Experimental Psychology: General* (Vol. 136).
- Puspitaningrum, D. 2006. *Pengantar Jaringan Saraf Tiruan.* Yogyakarta: Andi Yogyakarta.
- Rahardja Pratama, Mandala Manurung. 2010. *Teori Ekonomi Mikro.* Jakarta: Lembaga Universitas Indonesia
- Rau, V. (2018). Analisis Peramalan Permintaan Produk Hollow Brick Pada Ud. Immanuel Air Madidi. *Jurnal EMBA: Jurnal Riset Ekonomi, Manajemen, Bisnis Dan Akuntansi*, 6(3), 1498–1507.
- Rufiyanti, D. E. 2015. Implementasi Jaringan Saraf Tiruan *Backpropagation* dengan Input Model Arima untuk Peramalan Harga Saham, 1-124.
- Samuelson, Paul. A., Nordhaus, William. 2003. *Ilmu Mikroekonomi.* Jakarta: Erlangga.

- Santosa, Budi. 2017. Konsep Dasar Optimasi Pengantar Metaheuristik Implementasi dengan Matlab, 09-20 & 177-197.
- Saragih, M.Sc, F. H. (2017). Faktor-faktor yang Mempengaruhi Pendapatan Rumah Tangga Tani Padi. *Jurnal Agrica*, 9(2), 101. <https://doi.org/10.31289/agrica.v9i2.486>
- Shaputra, E., Ginting, B. S., Studi, P., Informatika, T., & Utara, S. (2021). *PREDIKSI PENDAPATAN ASLI DAERAH (PAD) KABUPATEN LANGKAT MENGGUNAKAN METODE BACKPROPAGATION*. 5(1), 69–75.
- Simanjuntak, J. (2021). Perkembangan Matematika dan Pendidikan Matematika Di Indonesia. *Sepren*, 2(2), 32–39. <https://doi.org/10.36655/sepren.v2i2.512>
- Siang J. J. 2005. *Jaringan Syaraf Tiruan & Pemrogramannya Menggunakan Matlab*. Yogyakarta: Andi Yogyakarta.
- Sri Kusumadewi dan Hari Purnomo. 2005. *Penyelesaian Masalah Optimasi dengan Teknik-Teknik Heuristik*. Yogyakarta: Graha Ilmu.
- Steven. 2014. Analisis Pengaruh E-Commerce Strategy, Service, Performance Terhadap Loyalitas Pelanggan dan Kepuasan Pelanggan Sebagai Variabel Intervening. *Journal Of Management*. 2.(2).
- Sujoto T, Mulyanto Edy, and Suhartono Vincent. 2010. Kecerdasan Buatan, Benedicta Rini, Ed. Semarang: Andi.

- Sukirno. 2006. *Mikro Ekonomi Teori Pengantar*. Jakarta: Unit Penerbit PT. Raja Grafindo Persada.
- Syahrudin, Adhiim Rizky, A., Jauhari, L., Fatimah, S., Ningsih, W., & Mandailina, V. (2020). Implementasi Metode Winter untuk Forecasting Pertumbuhan Jumlah Penduduk: Studi Kasus Wilayah Provinsi NTB. *Jurnal Pemikiran Dan Penelitian Pendidikan Matematika (JP3M)*, 3(1), 51–61. <https://doi.org/10.36765/jp3m.v3i1.243>
- Syahrudin, Pujiana, E., Sari, I. P., Mardika, V. M., & Putri, M. (2020). Analisis Algoritma Back Propagation Dalam Prediksi Angka Kemiskinan Di Indonesia. *J. Pendidik. Berkarakter*, 3(1), 11–17.
- Syarif, Admi. 2014. *ALGORITMA GENETIKA: Teori dan Aplikasi Edisi 2*. Yogyakarta: Graha Ilmu.
- Yamit, Zulian. 2003. *Manajemen Persediaan Edisi Z Ekonomi*. Yogyakarta: Fakultas Ekonomi UII.
- Yoga. 2015. Pengaruh Kualitas Pelayanan dan Kepercayaan Terhadap Loyalitas Pelanggan Dengan Kepuasan Pelanggan Sebagai Variabel Intervening. Studi Kasus Pelanggan di PT. Indo Samudera Perkasa Semarang. *Jurnal Of Management*. 4. (4).
- Zukhri, Zainudin. 2014. *Algoritma Genetika : Metode Komputasi Evolusioner untuk Menyelesaikan Masalah Optimasi*, Seno, Ed. Yogyakarta: Andi.

LAMPIRAN

Lampiran 1 Data Pendapatan JNE Express Sekaran Tahun 2019-2021

Bulan	Pendapatan
Januari 2019	24361000
Februari 2019	21801500
Maret 2019	23949500
April 2019	35972500
Mei 2019	53290394
Juni 2019	36285100
Juli 2019	51590000
Agustus 2019	50223000
September 2019	41087500
Oktober 2019	47542000
November 2019	39135000
Desember 2019	43100500
Januari 2020	49380500
Februari 2020	44812500
Maret 2020	55318000
April 2020	53993000
Mei 2020	66607000
Juni 2020	59741500
Juli 2020	72494000
Agustus 2020	50187000
September 2020	41279500
Oktober 2020	37261000
November 2020	38079500
Desember 2020	38333500
Januari 2021	51932000

Februari 2021	46327000
Maret 2021	34858500
April 2021	36604500
Mei 2021	33852000
Juni 2021	36615000
Juli 2021	57230000
Agustus 2021	44697500
September 2021	22866000

Lampiran 2 Pola *Input* dan *Output*

No	Input	Target
1	X ₁ , X ₂ , X ₃ , X ₄	Y ₁
2	X ₂ , X ₃ , X ₄ , X ₅	Y ₂
3	X ₃ , X ₄ , X ₅ , X ₆	Y ₃
4	X ₄ , X ₅ , X ₆ , X ₇	Y ₄
5	X ₅ , X ₆ , X ₇ , X ₈	Y ₅
6	X ₆ , X ₇ , X ₈ , X ₉	Y ₆
7	X ₇ , X ₈ , X ₉ , X ₁₀	Y ₇
8	X ₈ , X ₉ , X ₁₀ , X ₁₁	Y ₈
9	X ₉ , X ₁₀ , X ₁₁ , X ₁₂	Y ₉
10	X ₁₀ , X ₁₁ , X ₁₂ , X ₁₃	Y ₁₀
11	X ₁₁ , X ₁₂ , X ₁₃ , X ₁₄	Y ₁₁
12	X ₁₂ , X ₁₃ , X ₁₄ , X ₁₅	Y ₁₂
13	X ₁₃ , X ₁₄ , X ₁₅ , X ₁₆	Y ₁₃
14	X ₁₄ , X ₁₅ , X ₁₆ , X ₁₇	Y ₁₄
15	X ₁₅ , X ₁₆ , X ₁₇ , X ₁₈	Y ₁₅
16	X ₁₆ , X ₁₇ , X ₁₈ , X ₁₉	Y ₁₆
17	X ₁₇ , X ₁₈ , X ₁₉ , X ₂₀	Y ₁₇
18	X ₁₈ , X ₁₉ , X ₂₀ , X ₂₁	Y ₁₈
19	X ₁₉ , X ₂₀ , X ₂₁ , X ₂₂	Y ₁₉
20	X ₂₀ , X ₂₁ , X ₂₂ , X ₂₃	Y ₂₀
21	X ₂₁ , X ₂₂ , X ₂₃ , X ₂₄	Y ₂₁
22	X ₂₂ , X ₂₃ , X ₂₄ , X ₂₅	Y ₂₂
23	X ₂₃ , X ₂₄ , X ₂₅ , X ₂₆	Y ₂₃
24	X ₂₄ , X ₂₅ , X ₂₆ , X ₂₇	Y ₂₄
25	X ₂₅ , X ₂₆ , X ₂₇ , X ₂₈	Y ₂₅
26	X ₂₆ , X ₂₇ , X ₂₈ , X ₂₉	Y ₂₆
27	X ₂₇ , X ₂₈ , X ₂₉ , X ₃₀	Y ₂₇
28	X ₂₈ , X ₂₉ , X ₃₀ , X ₃₁	Y ₂₈

29	$X_{29}, X_{30}, X_{31}, X_{32}$	Y_{29}
30	$X_{30}, X_{31}, X_{32}, X_{33}$	Y_{30}
31	$X_{31}, X_{32}, X_{33}, X_{34}$	Y_{31}
32	$X_{32}, X_{33}, X_{34}, X_{35}$	Y_{32}

Lampiran 3 Normalisasi Data

	NORMALISASI				
	X ₁	X ₂	X ₃	X ₄	Y
1	0.1404	0.1000	0.1339	0.3236	0.5969
2	0.1000	0.1339	0.3236	0.5969	0.3286
3	0.1339	0.3236	0.5969	0.3286	0.5701
4	0.3236	0.5969	0.3286	0.5701	0.5485
5	0.5969	0.3286	0.5701	0.5485	0.4044
6	0.3286	0.5701	0.5485	0.4044	0.5062
7	0.5701	0.5485	0.4044	0.5062	0.3735
8	0.5485	0.4044	0.5062	0.3735	0.4361
9	0.4044	0.5062	0.3735	0.4361	0.5352
10	0.5062	0.3735	0.4361	0.5352	0.4631
11	0.3735	0.4361	0.5352	0.4631	0.6289
12	0.4361	0.5352	0.4631	0.6289	0.6080
13	0.5352	0.4631	0.6289	0.6080	0.8071
14	0.4631	0.6289	0.6080	0.8071	0.6987
15	0.6289	0.6080	0.8071	0.6987	0.9000
16	0.6080	0.8071	0.6987	0.9000	0.5480
17	0.8071	0.6987	0.9000	0.5480	0.4074
18	0.6987	0.9000	0.5480	0.4074	0.3440
19	0.9000	0.5480	0.4074	0.3440	0.3569
20	0.5480	0.4074	0.3440	0.3569	0.3609
21	0.4074	0.3440	0.3569	0.3609	0.5755
22	0.3440	0.3569	0.3609	0.5755	0.4870
23	0.3569	0.3609	0.5755	0.4870	0.3061
24	0.3609	0.5755	0.4870	0.3061	0.3336
25	0.5755	0.4870	0.3061	0.3336	0.2902
26	0.4870	0.3061	0.3336	0.2902	0.3338
27	0.3061	0.3336	0.2902	0.3338	0.6591

28	0.3336	0.2902	0.3338	0.6591	0.4613
29	0.2902	0.3338	0.6591	0.4613	0.1168
30	0.3338	0.6591	0.4613	0.1168	-0.2441
31	0.6591	0.4613	0.1168	-0.2441	-0.2441
32	0.4613	0.1168	-0.2441	-0.2441	-0.2441

Lampiran 4 *Transpose Data*

	1	2	3	4	5	6	7
X₁	0.1404	0.1000	0.1339	0.3236	0.5969	0.3286	0.5701
X₂	0.1000	0.1339	0.3236	0.5969	0.3286	0.5701	0.5485
X₃	0.1339	0.3236	0.5969	0.3286	0.5701	0.5485	0.4044
X₄	0.3236	0.5969	0.3286	0.5701	0.5485	0.4044	0.5062
Y	0.5969	0.3286	0.5701	0.5485	0.4044	0.5062	0.3735

Lanjutan

8	9	10	11	12	13	14	15
0.5485	0.4044	0.5062	0.3735	0.4361	0.5352	0.4631	0.6289
0.4044	0.5062	0.3735	0.4361	0.5352	0.4631	0.6289	0.6080
0.5062	0.3735	0.4361	0.5352	0.4631	0.6289	0.6080	0.8071
0.3735	0.4361	0.5352	0.4631	0.6289	0.6080	0.8071	0.6987
0.4361	0.5352	0.4631	0.6289	0.6080	0.8071	0.6987	0.9000

Lanjutan

16	17	18	19	20	21	22	23
0.6080	0.8071	0.6987	0.9000	0.5480	0.4074	0.3440	0.3569
0.8071	0.6987	0.9000	0.5480	0.4074	0.3440	0.3569	0.3609
0.6987	0.9000	0.5480	0.4074	0.3440	0.3569	0.3609	0.5755
0.9000	0.5480	0.4074	0.3440	0.3569	0.3609	0.5755	0.4870
0.5480	0.4074	0.3440	0.3569	0.3609	0.5755	0.4870	0.3061

Lanjutan

24	25	26	27	28	29
0.3609	0.5755	0.4870	0.3061	0.3336	0.2902
0.5755	0.4870	0.3061	0.3336	0.2902	0.3338

0.4870	0.3061	0.3336	0.2902	0.3338	0.6591
0.3061	0.3336	0.2902	0.3338	0.6591	0.4613
0.3336	0.2902	0.3338	0.6591	0.4613	0.1168

Lanjutan

30	31	32
0.3338	0.6591	0.4613
0.6591	0.4613	0.1168
0.4613	0.1168	-0.2441
0.1168	-0.2441	-0.2441
-0.2441	-0.2441	-0.2441

Lampiran 5 Hasil *Training* dan *Testing* Arsitektur 4-10-1

TRAINING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.5969	0.6010	-0.0041	1.714E-05	0.006936
0.3286	0.3156	0.0130	0.000168	0.03944
0.5701	0.5122	0.0579	0.0033547	0.101596
0.5485	0.5765	-0.0280	0.0007846	0.051067
0.4044	0.4922	-0.0878	0.0077018	0.217013
0.5062	0.4872	0.0190	0.0003602	0.037495
0.3735	0.4455	-0.0720	0.0051782	0.192664
0.4361	0.4076	0.0285	0.0008105	0.065283
0.5352	0.5162	0.0190	0.0003618	0.035538
0.4631	0.4611	0.0020	3.842E-06	0.004232
0.6289	0.5354	0.0935	0.0087479	0.14872
0.6080	0.5804	0.0276	0.0007634	0.045444
0.8071	0.7313	0.0758	0.0057426	0.093892
0.6987	0.7641	-0.0654	0.0042719	0.093545
0.9000	0.8158	0.0843	0.0070981	0.093611
0.5480	0.5346	0.0134	0.0001793	0.024434
0.4074	0.4844	-0.0770	0.0059244	0.18893
0.3440	0.3728	-0.0288	0.0008277	0.083634
0.3569	0.2970	0.0599	0.0035832	0.167722
0.3609	0.3744	-0.0135	0.0001817	0.037351
0.5755	0.5375	0.0380	0.0014425	0.065995
0.4870	0.4855	0.0015	2.19E-06	0.003039
0.3061	0.4917	-0.1856	0.0344622	0.606468
0.3336	0.3392	-0.0056	3.158E-05	0.016847
0.2902	0.2387	0.0515	0.0026512	0.177429
Total			0.0946507	
MSE			0.003786	

MAPE	0.103933
------	----------

TESTING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.3338	0.4507	-0.1169	0.0137	0.35021
0.6591	0.6628	-0.0037	0.000014	0.005599
0.4613	0.3223	0.1390	0.0193	0.301387
0.1168	0.4650	-0.3482	0.121229	2.980993
-0.2441	0.1507	-0.3948	0.1558	1.617206
-0.2441	0.0861	-0.3302	0.109025	1.352679
-0.2441	0.5537	-0.7978	0.6365	3.268497
Total			1.0556	
MSE			0.150807	
MAPE				1.410939

Lampiran 6 Hasil *Training* dan *Testing* Arsitektur 4-11-1

TRAINING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.5969	0.6045	-0.0076	5.74564E-05	0.01270
0.3286	0.3509	-0.0223	0.000495953	0.06777
0.5701	0.5700	0.0001	6.4E-09	0.00014
0.5485	0.5263	0.0222	0.00049284	0.04047
0.4044	0.4289	-0.0245	0.00060025	0.06058
0.5062	0.4503	0.0559	0.003129284	0.11051
0.3735	0.4067	-0.0332	0.001101576	0.08886
0.4361	0.4248	0.0113	0.000127916	0.02593
0.5352	0.5156	0.0196	0.000382594	0.03655
0.4631	0.4139	0.0492	0.002416706	0.10615
0.6289	0.5051	0.1238	0.015328916	0.19687
0.6080	0.6411	-0.0331	0.001097597	0.05449
0.8071	0.7966	0.0105	0.000111092	0.01306
0.6987	0.7408	-0.0421	0.001774094	0.06028
0.9000	0.7827	0.1174	0.013771023	0.13039
0.5480	0.5672	-0.0192	0.000369408	0.03507
0.4074	0.4190	-0.0116	0.000134328	0.02845
0.3440	0.3144	0.0296	0.000874976	0.08599
0.3569	0.1795	0.1774	0.031477856	0.49711
0.3609	0.3951	-0.0342	0.001168272	0.09471
0.5755	0.5877	-0.0122	0.000149573	0.02125
0.4870	0.4994	-0.0124	0.000153512	0.02544
0.3061	0.3588	-0.0527	0.002779398	0.17223
0.3336	0.40969	-0.0761	0.005789688	0.22809
0.2902	0.2749	0.0153	0.00023409	0.05272
Total			0.084018405	
MSE			0.003360736	

MAPE	0.08983
------	---------

TESTING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.3338	0.5208	-0.1870	0.034969	0.56022
0.6591	0.7579	-0.0988	0.009765	0.14993
0.4613	0.3550	0.1064	0.01131	0.23054
0.1168	0.2869	-0.1701	0.02892	1.45599
-0.2441	0.2204	-0.4645	0.215723	1.90274
-0.2441	0.1692	-0.4133	0.170833	1.69324
-0.2441	0.75796	-1.0021	1.004124	4.10512
Total			1.475646	
MSE			0.210807	
MAPE				1.44254

Lampiran 7 Hasil *Training* dan *Testing* Arsitektur 4-12-1

TRAINING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.5969	0.5940	0.0029	8.1796E-06	0.00479
0.3286	0.3329	-0.0043	1.8404E-05	0.01306
0.5701	0.5521	0.0180	0.00032508	0.03163
0.5485	0.5125	0.0360	0.00129888	0.06571
0.4044	0.4780	-0.0736	0.0054096	0.18187
0.5062	0.5506	-0.0444	0.00197491	0.08779
0.3735	0.4241	-0.0506	0.0025634	0.13556
0.4361	0.3980	0.0381	0.00145085	0.08734
0.5352	0.5244	0.0108	0.00011599	0.02012
0.4631	0.4286	0.0345	0.00119163	0.07454
0.6289	0.5505	0.0784	0.00614342	0.12463
0.6080	0.6433	-0.0353	0.00124397	0.05801
0.8071	0.7527	0.0544	0.00296371	0.06745
0.6987	0.6958	0.0029	8.4681E-06	0.00416
0.9000	0.9024	-0.0023	5.5225E-06	0.00261
0.5480	0.5455	0.0025	6.3001E-06	0.00458
0.4074	0.4049	0.0025	6.2001E-06	0.00611
0.3440	0.3374	0.0066	4.3824E-05	0.01924
0.3569	0.3493	0.0076	5.8522E-05	0.02143
0.3609	0.3486	0.0123	0.00015129	0.03408
0.5755	0.5924	-0.0169	0.00028561	0.02937
0.4870	0.4769	0.0101	0.0001014	0.02068
0.3061	0.3876	-0.0815	0.00664551	0.26632
0.3336	0.28914	0.0445	0.00197669	0.13327
0.2902	0.24435	0.0459	0.00210222	0.15799
Total			0.03609961	
MSE			0.00144398	

MAPE	0.06609
------	---------

TESTING				
AKTUAL	RAMALAN	ERROR	ERROR2	%ERROR
0.3338	0.5423	-0.2085	0.043485	0.62472
0.6591	0.2739	0.3852	0.148371	0.58442
0.4613	0.5746	-0.1133	0.01283	0.24555
0.1168	0.7945	-0.6777	0.45921	5.80180
-0.2441	0.2367	-0.4808	0.231197	1.96981
-0.2441	0.2018	-0.4459	0.198827	1.82671
-0.2441	-0.10178	-0.1423	0.020255	0.58304
Total			1.114175	
MSE			0.159168	
MAPE				1.66229

Lampiran 8 Data Prediksi Pendapatan

Bulan	Pendapatan	Prediksi Pendapatan
Januari 2019	24361000	25292244
Februari 2019	21801500	22932430
Maret 2019	23949500	24911802
April 2019	35972500	36317867
Mei 2019	53290394	53283503
Juni 2019	36285100	36622384
Juli 2019	51590000	51660439
Agustus 2019	50223000	50340014
September 2019	41087500	41339726
Oktober 2019	47542000	47719413
November 2019	39135000	39414427
Desember 2019	43100500	43331067
Januari 2020	49380500	49520380
Februari 2020	44812500	45025748
Maret 2020	55318000	55183277
April 2020	53993000	53946379
Mei 2020	66607000	64683546
Juni 2020	59741500	59153432
Juli 2020	72494000	68673843
Agustus 2020	50187000	50305002
Septemeber 2020	41279500	41529523
Oktober 2020	37261000	37575597
November 2020	38079500	38377297
Desember 2020	38333500	38626524
Januari 2021	51932000	51988610
Februari 2021	46327000	46522012
Maret 2021	34858500	35235673

April 2021	36604500	36934014
Mei 2021	33852000	34262200
Juni 2021	36615000	36944323
Juli 2021	57230000	56931487
Agustus 2021	44697500	44911776
September 2021	22866000	23911640

Data Prediksi Pendapatan *Backpropagation Artificial Neural Network*

Bulan	Data Aktual	Hasil Prediksi
Oktober 2021	24582000	29428187
November 2021	20797000	26187669
Desember 2021	41207000	63493547

Data Prediksi Pendapatan Algoritma Genetika

Bulan	Data aktual	Hasil Prediksi
Oktober 2021	24582000	25011603
November 2021	20797000	20920021
Desember 2021	41207000	50553019

Lampiran 9 Syntax Program *Backpropagation Artificial Neural Network*

1. Buka aplikasi matlab -> Membuat Workspace -> Klik kanan -> New -> Beri nama input_latih, input_uji, target_latih, target_uji
2. Double klik -> Muncul kolom untuk variables -> buka file excel yang sudah disiapkan -> copy dan paste ke kolom tersebut.
3. Variabel input_latih, input_uji, target_latih, target_uji diisi sesuai pola input datanya.
4. Tulis “nntool” pada command window -> enter
5. Import -> muncul jendela baru -> untuk variabel input_latih, input_uji import ke input data -> untuk variabel target_latih, target_uji import ke target data -> Oke -> Close.
6. Setelah data di import klik new -> muncul jendela baru, lalu isi ketentuannya sesuai yang diinginkan.
7. Klik Create -> Oke -> Close.
8. Double klik pada isi (judul/name) kolom networks.
Gambar arsitektur jaringan terbentuk.
9. Proses *training* jaringan. Train -> pada input isi dengan input_latih, target isi dengan target_latih
10. Klik training parameters -> tentukan nilai dari setiap parameternya dapat menggunakan default dari software,

lalu klik train network dan tunggu sampai software berhenti mentraining jaringan.

11. Proses *testing*. Pada jendela network: (isi kolom) klik simulate -> pada input isi dengan input_uji -> Ceklis supply targets -> isi targets dengan target_uji -> pada outpus ganti Namanya menjadi uji(sesuai isi kolom)_outputs pada errors ganti namanya menjadi uji(sesuai isi kolom)_errors -> simulate network -> oke.
12. Setelah data selesai ditraining dan diuji hasil dari *training* dan *testing* akan muncul pada jendela nntool pada kolom *output* data dan nilai *error* dari *training* dan *testing* ada di kolom error data.
13. Double klik pada masing-masing hasil -> ctrl+a -> copy
14. Pada command windows ketik nama datanya lalu =(tanpa spasi) -> paste.
15. Lakukan untuk semua hasil *training* dan *testing* beserta nilai errornya, lalu detransformasi/denormalisasi data.

Lampiran 10 Syntax Program Algoritma Genetika

FUNGSI-FUNGSI PADA ALGORITMA GENETIKA

BangMatrixIT

```
function [IM,TM] =  
BangMatrixIT(JumMasukan,JPmasukan);  
load dscopen g h  
for ii=1:JumMasukan,  
    IM(:,ii) = g(1:JPmasukan,ii);
```

```

    TM = h(1:JPmasukan,:);
end

```

Inisialisasi Populasi

```

function Populasi =
    InisialisasiPopulasi(UkPop, JumGen);
Populasi = fix(2*rand(UkPop, JumGen));

```

Dekodekan Kromosom

```

function x =
    DekodekanKromosom(Kromosom, Nvar, Nbit, Ra, Rb);
for ii=1:Nvar,
    x(ii) = 0;
    for jj=1:Nbit,
        x(ii) = x(ii) + Kromosom((ii-1)*Nbit+jj)*2^(-
jj);
    end
    x(ii) = Rb + ((Ra-Rb)*x(ii));
end

```

BinaryEvalInd

```

function fitness =
    BinaryEvalInd(FFNNstruk, JumMasukan, JPmasukan, IM,
    TM);
c = 1.0;
n2 = JumMasukan^2;

Wtemp = FFNNstruk(1:n2);
for ii=1:JumMasukan,
    Wih(ii,:) = Wtemp((ii-
1)*JumMasukan+1:ii*JumMasukan);
end

bih = FFNNstruk(n2+1:n2+JumMasukan);

```

```

Who =
FFNNstruk(n2+JumMasukan+1:n2+2*JumMasukan);
bho = FFNNstruk((JumMasukan+1)^2);
SSE = 0;
for evaluasi=1:JPmasukan,
    for ii=1:JumMasukan,
        SumWib = 0;
        for jj=1:JumMasukan,
            SumWib = SumWib + (Wih(ii,jj) *
IM(evaluasi,jj) + bih(jj));
        end
        Xih(ii) = 1 / (1+exp(-c*SumWib));
    end

    SumWXb = 0;
    for jj=1:JumMasukan,
        SumWXb = SumWXb + (Who(jj) * Xih(jj) +
bho);
    end
    Xho = 1 / (1+exp(-c*SumWXb));
    SSE = SSE + (TM(evaluasi)-Xho)^2;
end

MSE = (1/JPmasukan * SSE);
fitness = 1/MSE;

```

LinearFitness Ranking

```

function LFR =
LinearFitnessRanking(UkPop,Fitness,MaxF,MinF)

[SF,IndF] = sort(Fitness);

for rr=1:UkPop,
    LFR(IndF(UkPop-rr+1)) = MaxF- (MaxF-MinF)*((rr-
1)/(UkPop-1));
end

```

Roulette-Wheel

```

function Pindex =
RouletteWheel(UkPop,LinearFitness);

JumFitness = sum(LinearFitness);
KumulatifFitness = 0;
RN = rand;
ii = 1;
while ii <= UkPop,
    KumulatifFitness = KumulatifFitness +
LinearFitness(ii);
    if (KumulatifFitness/JumFitness) > RN,
        Pindex = ii;
        break;
    end
    ii = ii + 1;
end

```

PindahSilang

```

function Anak = PindahSilang(Bapak,Ibu,JumGen);

TP = 1 + fix(rand*(JumGen-1));

Anak(1,:) = [Bapak(1:TP) Ibu(TP+1:JumGen)];
Anak(2,:) = [Ibu(1:TP) Bapak(TP+1:JumGen)];

```

Mutasi

```

function MutKrom =
Mutasi(Kromosom,JumGen,Pmutasi);

MutKrom = Kromosom;
for ii=1:JumGen,
    if (rand < Pmutasi),
        if Kromosom(ii)==0,
            MutKrom(ii) = 1;
        else
            MutKrom(ii) = 0;
        end
    end
end

```

```

        end
    end
end

```

ALGORITMA GENETIKA BINARY ENCODING

```

clear all;close all;clc;
x1 =xlsread('bulan.xlsx',1,'B1:B34');
x2 =xlsread('bulan.xlsx',1,'C1:C34');
x3 =xlsread('bulan.xlsx',1,'D1:D34');
input=[x1;x2;x3];
save INPUT input
load INPUT input
tx=xlsread('bulan.xlsx',1,'B2:B35');
output=tx;

a=min(min(input));
b=max(max(input));
p=[0.8*(input-a)/(b-a)+0.1];
t=[0.8*(output-a)/(b-a)+0.1];
g=p';
h=t';
save dscopen g h
load dscopen g h
[JpMasukan,JumMasukan]=size(g)
Nbit = 10;
JumGen = Nbit*(JumMasukan+1)^2;
Nvar = JumGen/Nbit;
Rb = -10;
Ra = 10;
MinMSE = 0.0001;
Fthreshold = 1/MinMSE;
Bgraf = Fthreshold;

UkPop = 200;
Psilang = 0.8;
Pmutasi = 0.03;
MaxG = 4000;

hfig = figure;

```

```

hold on
title('Algoritma Genetika dengan Binary Encoding
untuk pelatihan FFNN');
set(hfig, 'position', [50,50,600,400]);
set(hfig, 'DoubleBuffer', 'on');
axis([1 MaxG 0 Bgraf]);
hbestplot1 = plot(1:MaxG,zeros(1,MaxG));
hbestplot2 = plot(1:MaxG,zeros(1,MaxG));
htext1 =
text(0.6*MaxG,0.25*Bgraf,sprintf('Fitness
terbaik: %7.6f', 0.0));
htext2 = text(0.6*MaxG,0.20*Bgraf,sprintf('MSE:
%7.6f', 0.0));
htext3 =
text(0.6*MaxG,0.15*Bgraf,sprintf('Ukuran
populasi: %3.0f', 0.0));
htext4 = text(0.6*MaxG,0.10*Bgraf,sprintf('Prob.
Pindah Silang: %4.3f', 0.0));
htext5 = text(0.6*MaxG,0.05*Bgraf,sprintf('Prob.
Mutasi: %4.3f', 0.0));
xlabel('Generasi');
ylabel('Fitness');
hold off
drawnow;

[IM,TM] = BangMatrixIT(JumMasukan,JPmasukan);

Populasi = InisialisasiPopulasi(UkPop,JumGen);

for generasi=1:MaxG,
    FFNNstruk =
    DekodekanKromosom(Populasi(1,:),Nvar,Nbit,Ra,Rb)
    ;
    Fitness(1) =
    BinaryEvalInd(FFNNstruk,JumMasukan,JPmasukan,IM,
    TM);
    MaxF = Fitness(1);
    MinF = Fitness(1);
    IndeksIndividuTerbaik = 1;
    for ii=2:UkPop,

```

```

        FFNNstruk =
DekodekanKromosom (Populasi (ii, :), Nvar, Nbit, Ra, Rb
);
        Fitness(ii) =
BinaryEvalInd (FFNNstruk, JumMasukan, JPmasukan, IM,
TM);
        if (Fitness(ii) > MaxF),
            MaxF = Fitness(ii);
            IndeksIndividuTerbaik = ii;
            FFNNterbaik = FFNNstruk;
        end
        if (Fitness(ii) <= MinF),
            MinF = Fitness(ii);
        end
    end

MSE = 1 / (MaxF);

plotvector1 = get(hbestplot1, 'YData');
plotvector1(generasi) = MaxF;
set(hbestplot1, 'YData', plotvector1);
plotvector2 = get(hbestplot2, 'YData');
set(hbestplot2, 'YData', plotvector2);
set(htext1, 'String', sprintf('Fitness
terbaik: %7.6f', MaxF));
set(htext2, 'String', sprintf('MSE: %7.6f',
MSE));
set(htext3, 'String', sprintf('Ukuran
populasi: %3.0f', UkPop));
set(htext4, 'String', sprintf('Prob. Pindah
Silang: %4.3f', Psilang));
set(htext5, 'String', sprintf('Probabilitas
Mutasi: %4.3f', Pmutasi));
drawnow

    if MaxF > Fthreshold,
        break;
    end

    TemPopulasi = Populasi;
    if mod(UkPop, 2) == 0,

```

```

        IterasiMulai = 3;
        TemPopulasi(1,:) =
Populasi (IndeksIndividuTerbaik,:);
        TemPopulasi(2,:) =
Populasi (IndeksIndividuTerbaik,:);
        TemPopulasi(3,:) =
Populasi (IndeksIndividuTerbaik,:);
    else
        IterasiMulai = 2;
        TemPopulasi(1,:) =
Populasi (IndeksIndividuTerbaik,:);
    end

    LinearFitness =
LinearFitnessRanking (UkPop,Fitness,MaxF,MinF);

    for jj=IterasiMulai:2:UkPop,
        IP1 =
RouletteWheel (UkPop,LinearFitness);
        IP2 =
RouletteWheel (UkPop,LinearFitness);
        if (rand < Psilang),
            Anak =
PindahSilang (Populasi (IP1,:),Populasi (IP2,:),Jum
Gen);
            TemPopulasi(jj,:) = Anak(1,:);
            TemPopulasi(jj+1,:) = Anak(2,:);
        else
            TemPopulasi(jj,:) = Populasi (IP1,:);
            TemPopulasi(jj+1,:) =
Populasi (IP2,:);
        end
    end
    for kk=IterasiMulai:UkPop,
        TemPopulasi(kk,:) =
Mutasi (TemPopulasi(kk,:),JumGen,Pmutasi);
    end

    Populasi = TemPopulasi;
end

```

```

FFNNterbaik
save FFNNterbaikOPEN.mat FFNNterbaik
saveas(gcf, 'GAopen.fig');

```

PREDIKSI FEED-FORWARD ALGORITMA GENETIKA

```

c = 1.0;
n2 = JumMasukan^2;
FFNNstruk=FFNNterbaik;
Wtemp = FFNNstruk(1:n2);
for ii=1:JumMasukan,
    Wih(ii,:) = Wtemp((ii-
1)*JumMasukan+1:ii*JumMasukan);
end
bih = FFNNstruk(n2+1:n2+JumMasukan);
Who =
FFNNstruk(n2+JumMasukan+1:n2+2*JumMasukan);
bho = FFNNstruk((JumMasukan+1)^2);
SSE = 0;
for evaluasi=1:JPmasukan,
    for ii=1:JumMasukan,
        SumWib = 0;
        for jj=1:JumMasukan,
            SumWib = SumWib + (Wih(ii,jj) *
IM(evaluasi,jj) + bih(jj));
        end
        Xih(ii) = 1 / (1+exp(-c*SumWib));
    end
    SumWXb = 0;
    for jj=1:JumMasukan,
        SumWXb = SumWXb + (Who(jj) * Xih(jj) +
bho);
    end
    xtt(evaluasi) = (((1 / (1+exp(-c*SumWXb)) -
0.1)*(b-a)/0.8)+a);
end
n=1:length(xtt);
figure(1);
plot(n,output,'r.-',n,xtt,'b.-');
title('data real vs prediksi
pendapatan');xlabel('banyak data');

```

```
ylabel('pendapatan');legend('data  
real','prediksi');  
save openGA output xtt  
saveas(gcf,'openGA.fig');
```

RIWAYAT HIDUP

A. Identitas Diri

Nama : Achmad Yusuf Naufal
TTL : Semarang, 28 Agustus 2000
Alamat : Jl. Taman Siswa Sekaran No.7 RT 01
RW 02, GunungPati, Semarang, Jawa
Tengah, 50229
No. HP : 085655734611
Email : ynaufal7@gmail.com
Instagram : @yusufnaufall

B. Riwayat Pendidikan

- | | |
|----------------------|------------------|
| 1. SD N 1 Sekaran | Lulus Tahun 2012 |
| 2. SMP N 3 Ungaran | Lulus Tahun 2015 |
| 3. SMA N 12 Semarang | Lulus Tahun 2018 |

C. Pengalaman Organisasi

1. Ketua Umum UKM Saintek Sport Periode 2020-2021