

# **PERBANDINGAN METODE AUTOREGRESIVE MOVING AVERAGE DAN EXTREME LEARNING MACHINE PADA PREDIKSI JUMLAH PENYERAPAN TENAGA KERJA**

(Studi Kasus: Data Buruh Pabrik di PT. Boyang Industrial 2016-2021)

## **TUGAS AKHIR**

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Program Studi Statistika



Disusun Oleh:  
Andini Nur Amalina  
18611028

**PROGRAM STUDI STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS ISLAM INDONESIA  
YOGYAKARTA  
2021**

**HALAMAN PERSETUJUAN PEMBIMBING  
TUGAS AKHIR**

Judul : Perbandingan Metode *Autoregressive Integrated Moving Average* dan *Extreme Learning Machine* pada  
Prediksi Penyerapan Tenaga Kerja (Studi Kasus :  
Data Jumlah Buruh Pabrik di PT. Boyang Industrial  
2016-2021)


Nama Mahasiswa : Andini Nur Amalina


NIM : 18611028

**TUGAS AKHIR INI TELAH DIPERIKSA DAN DISETUJUI UNTUK DIUJIKAN**

Yogyakarta, 29 Maret 2022  
Pembimbing

Yogyakarta, 5 April 2022  
Ketua Program Studi Statistika

  
(Dr. Edy Widodo, S.Si., M.Si.)

  
(Dr. Edy Widodo, S.Si., M.Si.)

## HALAMAN PENGESAHAN

### TUGAS AKHIR

#### PERBANDINGAN METODE AUTOREGRESIVE MOVING AVERAGE DAN EXTREME LEARNING MACHINE PADA PREDIKSI JUMLAH PENEYARAPAN TENAGA KERJA

(Studi Kasus: Data Buruh Pabrik di PT. Boyang Industrial 2016-2021)

Nama Mahasiswa : Andini Nur Amalina  
NIM : 18611028

TUGAS AKHIR INI TELAH DIUJIKAN  
PADA TANGGAL : 8 APRIL 2022

Nama Penguji

Tanda Tangan

1. Achmad Fauzan, S.Pd., M.Si.

2. Dina Tri Utari, S.Si., M.Sc.

3. Dr. Edy Widodo, S.Si., M.Si

Mengetahui,  
Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

(Prof. Riyanto, S.Pd., M.Si., Ph.D.)



## KATA PENGANTAR



*Assalamualaikum Wr.Wb*

Puji syukur kehadiran Allah SWT yang telah melimpahkan rahmat, nikmat serta hidayah-Nya sehingga penulis diberikan berkah, kesabaram, dan kelancaran sehingga penulis dapat menyelesaikan penulisan tugas akhir ini. Shalawat serta salam terlimpahkan kepada junjungan kita Nabi besar Muhammad SAW yang kita harapkan syafa'atnya di yaumul akhir.

Tugas akhir ini disusun sebagai salah satu persyaratan untuk memperoleh gelar Sarjana Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia. Tugas akhir yang berjudul “Perbandingan Metode *Autoregressive Moving Average* dan *Extreme Learning Machine* Pada Prediksi Jumlah Penyerapan Tenaga Kerja (Studi Kasus: Data Jumlah Buruh Pabrik di PT. Boyang Industrial Tahun 2016-2021)” dan harapannya dapat memberikan wawasan dan mengenalkan penerapan ilmu statistika dalam hal pengolahan data.

Penyelesaian tugas akhir ini tidak terlepas dari bantuan, arahan, dan bimbingan dari berbagai pihak. Oleh karena itu pada kesempatan ini penulis bermaksud menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

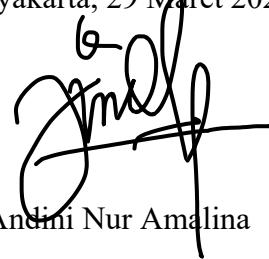
1. Bapak Fathul Wahid, S.T., M.Sc., Ph.D selaku Rektor Universitas Islam Indonesia
2. Bapak Prof.Riyanto, S.Pd., M.Si., Ph.D selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia.
3. Bapak Dr. Edy Widodo, S.Si., M.Si selaku Ketua Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia sekaligus dosen pembimbing tugas akhir.
4. Seluruh dosen pengajar Program Studi Statistika Universitas Islam Indonesia yang telah memberikan bekal ilmu kepada penulis selama

kurang lebih 4 tahun, serta seluruh staf dan laboran yang ada di Program Studi Statistika.

5. PT. Boyang Industrial yang sudah mengijinkan peneliti mengambil data.
6. Orang tua tersayang Bapak Hendri Krismoro dan Ibu Sri Umiyati yang menjadi motivasi terbesar penulis dan selalu memberikan do'a dan dukungan selama kuliah dan sampai tahap ini.
7. Teman-teman yang menemani dan *mensupport* mengerjakan skripsi.
8. Semua pihak yang telah membantu yang tidak dapat penulis sebutkan satu per satu.

*Wassalamualaikum Wr.Wb*

Yogyakarta, 29 Maret 2022



Andini Nur Amalina

## DAFTAR ISI

HALAMAN JUDUL .....	1
HALAMAN PENGESAHAN .....	2
KATA PENGANTAR.....	4
DAFTAR ISI .....	vi
DAFTAR TABEL .....	viii
DAFTAR GAMBAR.....	ix
DAFTAR LAMPIRAN .....	x
PERNYATAAN .....	xi
INTISARI .....	xii
ABSTRACT .....	xiii
BAB I PENDAHULUAN .....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah .....	5
1.3. Batasan Masalah.....	5
1.4. Tujuan Penelitian .....	6
1.5. Manfaat Penelitian .....	6
BAB II TINJAUAN PUSTAKA.....	7
2.1. <i>Autoregressive Integrated Moving Average</i> .....	7
2.2. <i>Autoregressive Moving Average</i> .....	8
2.3. Extreme Learning Machine.....	9
BAB III LANDASAN TEORI.....	23
3.1. Rambut Palsu .....	23
3.2. <i>Alopecia Areata</i> .....	23
3.3. Buruh Pabrik .....	24
3.4. Ekspor .....	24
3.5. Statistika Deskriptif.....	24
3.6. <i>Forecasting</i> .....	25
3.7. <i>Time Series</i> .....	25
3.8. <i>Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)</i> .....	27
3.9. <i>Autoregressive (AR)</i> .....	29
3.10. <i>Moving Average (MA)</i> .....	30
3.11. <i>Autoregressive Moving Average (ARMA)</i> .....	30
3.12. <i>Autoregressive Integrated Moving Average (ARIMA)</i> .....	30
3.13. Langkah Metode ARMA .....	32
3.14. Jaringan Syaraf Tiruan .....	34
3.15. <i>Extreme Learning Machine</i> .....	37
3.16. Tingkat Signifikansi dan <i>P-value</i> .....	42
3.17. Ukuran Kesalahan Peramalan.....	42
BAB IV METODOLOGI PENELITIAN .....	44
4.1. Populasi Penelitian .....	44
4.2. Variabel penelitian .....	44
4.3. Teknik Pengambilan Data .....	44
4.4. Metode Analisis Data .....	44
4.5. Tahap Penelitian Metode ARMA.....	46

4.6.	Tahap Penelitian Metode ELM .....	48
	BAB V HASIL DAN PEMBAHASAN.....	50
5.1.	Analisis Deskriptif .....	50
5.2.	Metode <i>Autoregressive Moving Average</i> (ARMA) .....	52
5.2.1	Membuat Plot .....	52
5.2.2	Pembagian Data Training dan Data Testing .....	52
5.2.3	Uji Stasioneritas Rata-Rata .....	54
5.2.4	Uji Stasioneritas Varians.....	55
5.2.5	Menentukan Model ARMA .....	56
5.2.6	Estimasi Parameter.....	58
5.2.7	Uji Diagnostik .....	59
5.2.8	Pemilihan Metode Terbaik.....	59
5.2.9	Peramalan dengan Metode ARMA .....	60
5.2.10	Akurasi Peramalan .....	61
5.3.	Metode <i>Extreme Learning Machine</i> .....	61
5.3.1	Normalisasi Data.....	61
5.3.2	Pembagian Data <i>Training</i> dan Data <i>Testing</i> .....	62
5.3.3	Arsitektur Jaringan .....	62
5.3.4	Peramalan dengan Metode <i>Extreme Learning Machine</i> .....	63
5.3.5	Akurasi Peramalan .....	64
5.4.	Hasil Prediksi Kedua Metode.....	65
	BAB VI PENUTUP .....	66
6.1.	Kesimpulan .....	66
6.2.	Saran.....	66
	DAFTAR PUSTAKA.....	67
	LAMPIRAN .....	73

## DAFTAR TABEL

<b>Tabel 2. 1</b> Perbandingan dengan Penelitian Sebelumnya .....	12
<b>Tabel 3. 1</b> Contoh Mencari Nilai ACF Lag 1 .....	27
<b>Tabel 3. 2</b> Contoh Mencari Nilai ACF Lag 2 .....	28
<b>Tabel 3. 3</b> Contoh Mencari Nilai AIC .....	33
<b>Tabel 3. 4</b> Pola Data <i>Training</i> .....	39
<b>Tabel 3. 5</b> Kategori Ukuran Kesalahan .....	42
<b>Tabel 3. 6</b> Contoh Mencari Nilai MAPE .....	43
<b>Tabel 5. 1</b> Tabel perhitungan konstanta persamaan linear .....	50
<b>Tabel 5. 2</b> Tabel hasil perhitungan persamaan linear .....	51
<b>Tabel 5. 3</b> Pembagian Data <i>Training</i> dan Data <i>Testing</i> ARMA .....	52
<b>Tabel 5. 4</b> Hasil Pembagian Data <i>Training</i> Jumlah Buruh Pabrik .....	53
<b>Tabel 5. 5</b> Hasil Pembagian Data <i>Testing</i> Jumlah Buruh Pabrik .....	54
<b>Tabel 5. 6</b> Hasil Uji Stasioneritas Rata-Rata .....	55
<b>Tabel 5. 7</b> Hasil Uji Stasioneritas Varians ( <i>R Studio</i> ) .....	55
<b>Tabel 5. 8</b> Hasil Uji Stasioneritas Varians Setelah di Transformasi .....	55
<b>Tabel 5. 9</b> thitung dari masing-masing parameter .....	58
<b>Tabel 5. 10</b> <i>P-value</i> dari masing-masing parameter .....	59
<b>Tabel 5. 11</b> Hasil Peramalan Metode ARMA(2, 0, 1) .....	60
<b>Tabel 5. 12</b> Nilai MAPE ARMA .....	61
<b>Tabel 5. 13</b> Hasil Normalisasi .....	61
<b>Tabel 5. 14</b> Pembagian Data <i>Training</i> dan Data <i>Testing</i> ELM .....	62
<b>Tabel 5. 15</b> Uji Coba <i>Hidden Layer</i> .....	63
<b>Tabel 5. 16</b> Hasil Peramalan Metode ELM .....	63
<b>Tabel 5. 17</b> Nilai MAPE ELM .....	64
<b>Tabel 5. 18</b> Perbandingan Metode Terbaik .....	65



## DAFTAR GAMBAR

<b>Gambar 1. 1</b>	Jumlah Karyawan PT. Boyang Industrial.....	2
<b>Gambar 1. 2</b>	Hasil Ekspor Rambut Palsu PT. Boyang Industrial.....	3
<b>Gambar 3. 1</b>	Tipe dari <i>Alopecia Areata</i> .....	23
<b>Gambar 3. 5</b>	Pola data <i>Time Series</i> .....	26
<b>Gambar 3. 6</b>	Sel Syaraf Biologi.....	35
<b>Gambar 3. 7</b>	<i>Single Layer Network</i> .....	35
<b>Gambar 3. 8</b>	<i>Multi Layer Network</i> .....	36
<b>Gambar 3. 9</b>	<i>Reccurent Neutral Network</i> .....	36
<b>Gambar 3. 10</b>	Struktur ELM.....	37
<b>Gambar 4. 1</b>	Diagram Alir ARMA.....	47
<b>Gambar 4. 2</b>	Diagram Alir ELM .....	49
<b>Gambar 5. 1</b>	Grafik Jumlah Buruh Pabrik.....	50
<b>Gambar 5. 3</b>	Grafik Buruh Pabrik Tahun 2016-2021 .....	52
<b>Gambar 5. 4</b>	Plot ACF dan PACF .....	56
<b>Gambar 5. 5</b>	Plot Uji Diagnostik ARMA(2, 0, 1) .....	59
<b>Gambar 5. 6</b>	Grafik Hasil Peramalan ARMA(2, 0, 1).....	60
<b>Gambar 5. 7</b>	Arsitektur Jaringan .....	62
<b>Gambar 5. 8</b>	Grafik Peramalan ELM .....	64

## DAFTAR LAMPIRAN

Lampiran 1 .....	73
Lampiran 2 .....	75
Lampiran 3 .....	63

## PERNYATAAN

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya karya yang sebelumnya pernah diajukan untuk memperoleh gelar kesarjanaan di suatu Perguruan Tinggi dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan orang lain, kecuali yang diacu dalam naskah ini dan disebutkan dalam daftar pustaka.

Yogyakarta, 29 Maret 2022



The image shows a 1000 Rupiah postage meter stamp. The stamp features the Garuda Pancasila emblem and the text 'REPUBLIK INDONESIA', '1000', 'METERI', and 'TAMPAK'. A handwritten signature is written over the stamp. Below the stamp, the name '(Andini Nur Amalina)' is printed.

(Andini Nur Amalina)

## INTISARI

### PERBANDINGAN METODE AUTOREGRESIVE MOVING AVERAGE DAN EXTREME LEARNING MACHINE PADA PREDIKSI JUMLAH PENEYARAPAN TENAGA KERJA

(Studi Kasus: Data Buruh Pabrik di PT. Boyang Industrial 2016-2021)

Andini Nur Amalina (18611028)

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Islam Indonesia

Sektor ekonomi di Purbalingga yang paling pesat pertumbuhannya adalah sektor industri. Hal ini memberi dampak positif bagi perekonomian masyarakat Purbalingga terutama dari sisi penyerapan tenaga kerja. Sektor industri pengolahan rambut di Purbalingga merupakan sektor mampu menyerap tenaga kerja paling banyak diantara sektor yang lainnya, yaitu lebih dari 34,06% tenaga kerja. Oleh karena itu dilakukan peramalan terhadap jumlah penyerapan tenaga kerja di PT. Boyang Industrial. Penelitian ini membandingkan 2 metode yaitu metode *Autoregressive Moving Average* (ARMA) dan metode *Extreme Learning Machine* (ELM) dalam meramalkan kemampuan penyerapan tenaga kerja dengan data jumlah buruh pabrik di PT. Boyang Industrial Purbalingga tahun 2022. Metode ARMA ini merupakan metode peramalan data runtun waktu yang memanfaatkan data historis dan data sekarang untuk menghasilkan peramalan jangka pendek yang akurat. Metode ELM merupakan metode pembelajaran baru dari jaringan syaraf tiruan yang memiliki learning speed yang cepat dan juga akurasi yang baik. Berdasarkan nilai MAPE menunjukkan bahwa metode ARMA(2, 0, 1) lebih tepat digunakan untuk meramalkan studi kasus, karena memiliki nilai MAPE yang lebih kecil dibandingkan dengan metode ELM. Didapatkan tingkat kesalahan peramalan sebesar 0,2454%. Sedangkan metode ELM dengan jumlah hidden layer sebanyak 8 menghasilkan nilai MAPE sebesar 10,7315%.

**Kata Kunci:** Jumlah Buruh Pabrik, Prediksi, MAPE, *Auto Regressive Moving Average*, *Extreme Learning Machine*

## ABSTRACT

### ***COMPARISON OF AUTOREGRESSIVE MOVING AVERAGE AND EXTREME LEARNING MACHINE ON THE PREDICTION OF NUMBER OF LABOR EMPLOYMENT***

*(Case Study: Dataset of Number of Factory Workers at PT.Boyang Industrial  
2016-2021)*

Andini Nur Amalina

Department of Statistics, Faculty of Matematics and Natural Sciences  
Universitas Islam Indonesia

*The fastest growing economic sector in Purbalingga is the industrial sector. This has a positive impact on the economy of the Purbalingga community, especially in terms of employment. The hair processing industry sector in Purbalingga is a sector capable of absorbing the most labor among other sectors, which is more than 34.06% of the workforce. Therefore, forecasting is carried out on the number of labor absorption at PT. Boyang Industrial. This study compares 2 methods, namely the Autoregressive Moving Average (ARMA) method and the Extreme Learning Machine (ELM) method in predicting the ability to absorb labor with data on the number of factory workers at PT. Boyang Industrial Purbalingga 2022. This ARMA method is a time series data forecasting method that utilizes historical data and current data to produce accurate short-term forecasts. The ELM method is a new learning method from an artificial neural network that has a fast learning speed and good accuracy. Based on the MAPE value, it shows that the ARMA(2, 0, 1) method is more appropriate to use for forecasting case studies, because it has a smaller MAPE value than the ELM method. The forecasting error rate is 0.2454%. While the ELM method with 8 hidden layers produces a MAPE value of 10.7315%.*

**Keywords:** *Number of Factory Workers, Prediction, MAPE, Auto Regressive Moving Average, Extreme Learning Machine*

# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Pertumbuhan ekonomi di Kabupaten Purbalingga mengalami peningkatan yang cukup drastis seiring dengan berkembangnya sektor-sektor ekonomi di masyarakat. Sektor ekonomi yang paling pesat pertumbuhannya adalah sektor industri yang ditandai dengan berdirinya banyak industri kerajinan rambut palsu baik di skala rumah tangga maupun industri besar. Pertumbuhan industri kerajinan rambut yang sangat pesat memberikan dampak yang sangat positif bagi perekonomian masyarakat Purbalingga terutama dari sisi penyerapan tenaga kerja. Dari 322 perusahaan yang ada, perusahaan yang menyerap tenaga kerja dalam jumlah paling besar adalah perusahaan pengolahan rambut. Hal inilah yang menjadikan penyerapan tenaga kerja di sektor pengolahan di Purbalingga menjadi paling tinggi diantara sektor-sektor yang lainnya, yaitu lebih dari 34,06% tenaga kerja terserap pada sektor pengolahan rambut palsu (Agustina, 2018).

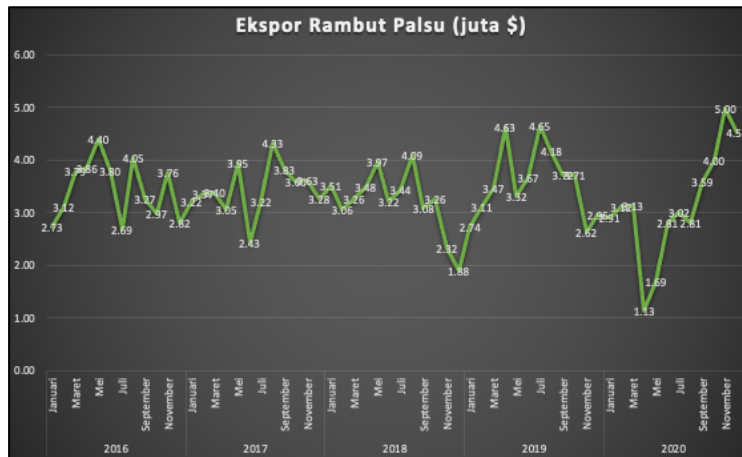
Menurut KBBI, wig merupakan rambut tiruan/rambut buatan/rambut palsu yang digunakan sebagai penutup kepala. Pemakaian rambut palsu adalah salah satu pilihan yang tepat untuk mengembalikan rasa kepercayaan diri. Seperti halnya rambut palsu atau wig yang digunakan untuk menutupi kepala yang botak karena alasan medis, digunakan bagi mereka yang sedang menjalani kemoterapi dan penderita *alopecia aerata*. *Alopecia aerata* merupakan kondisi ketika seseorang mengidap suatu penyakit autoimun bersifat kronis yang menyebabkan kebutakan tanpa disertai pembentukan jaringan parut. Penyakit ini menyerang folikel rambut yang menyebabkan rambut rontok dan menimbulkan kebutakan (Darwin, 2018). Selain alasan medis, penggunaan rambut palsu atau wig bisa juga digunakan sebagai aksesoris *fashion* bagi mereka yang ingin tampil beda dengan gaya maupun warna rambut yang berbeda. Dengan begitu mereka tidak perlu mengorbankan gaya atau warna rambut asli mereka.



**Gambar 1. 1** Jumlah Karyawan PT. Boyang Industrial  
Sumber: PT. Boyang Industrial

PT. Boyang Industrial ini yang bertempat di Jl. Jend. Ahmad Yani No.4-A, Kandang Gampang, Kec. Purbalingga, Kabupaten Purbalingga, Jawa Tengah ini telah mempekerjakan ribuan buruh yang tentunya membantu mengurangi kasus pengangguran di Purbalingga. Bahkan PT. Boyang Industrial mampu bertahan ditengah pandemi Covid-19 ini walaupun sempat melakukan pemberhentian kerja terhadap 1.984 orang di bulan Mei 2020 yang sebelumnya mempekerjakan 7.556 buruh di bulan Januari tahun 2020. Pemutusan hubungan kerja atau PHK merupakan hal yang sangat meresahkan dan merugikan bagi para buruh pabrik (Putri & dkk, 2021). Industri pengolahan rambut palsu atau wig merupakan industri yang kredibel untuk mempercepat laju perekonomian dan mengurangi tingkat pengangguran di Kabupaten Purbalingga.

Kabupaten Purbalingga merupakan kota industri global menurut situs laman resmi Dinas Penanaman Modal dan Pelayanan Terpadu Satu Pintu Kabupaten Purbalingga. Kabupaten Purbalingga Jawa Tengah menyumbangkan 56,10% investasi industri di seluruh Indonesia dengan nilai 19.033.000 US\$ dari total 21.985.000 US\$ dalam skala nasional. Investasi terbesar disumbang dari sektor industri rambut palsu.



**Gambar 1. 2** Hasil Ekspor Rambut Palsu PT. Boyang Industrial  
 Sumber: PT. Boyang Industrial

Berdasarkan grafik tersebut di atas hasil ekspor rambut palsu dari PT.Boyang Industrial mengalami fluktuasi, pendapatan dari hasil ekspor terendah berada pada bulan April 2020 yaitu sebesar 1.13 juta US\$ yang merupakan dampak adanya pandemi Covid-19. Pandemi COVID-19 yang telah menyebar pada Maret 2020 di Indonesia membawa risiko yang sangat buruk bagi perekonomian dunia termasuk Indonesia khususnya dari sisi pariwisata, perdagangan serta investasi (Nasution, Erlina, & Muda, 2020). Walaupun dengan adanya pandemi Covid-19 ini PT. Boyang Industrial tetap beroperasi dengan taat mengikuti protokol kesehatan yang telah ditetapkan oleh pemerintah. PT. Boyang industrial berhasil mengalami peningkatan pendapatan di bulan November 2020 yaitu sebesar 5 juta US\$.

Peramalan atau prediksi yang akurat diperlukan agar memperoleh informasi tentang perubahan kemampuan penyerapan tenaga kerja buruh yang bekerja di masa yang akan datang, supaya PT. Boyang Industrial dapat mempersiapkannya dari segala sisi. Contohnya, dengan adanya peramalan, PT. Boyang Industrial dapat mengkaji kebijakan yang tepat dalam hal produksi rambut palsu. Karena di PT. Boyang Industrial rambut palsu dibuat secara manual oleh para buruh pabrik. Banyak sedikitnya rambut yang diproduksi dipengaruhi oleh jumlah faktor buruh yang bekerja, berapa jumlah rambut palsu yang dihasilkan tiap harinya dipengaruhi jumlah buruh yang bekerja. Dengan adanya prediksi, PT. Boyang Industrial dapat memperkirakan antara permintaan produksi dan jumlah buruh yang bekerja, jumlah hari yang diperlukan untuk menyelesaikan permintaan dan lain sebagainya, jika terjadi kekurangan buruh maka akan terjadi keterlambatan produksi.



Peramalan merupakan suatu metode yang digunakan untuk meramalkan suatu nilai dimasa depan dengan menggunakan data masa yang telah ada (Wardah & Iskandar, 2016). Peramalan dengan metode data *time series Autoregressive Moving Average* (ARMA) adalah salah satu metode peramalan gabungan antara *Autoregressive* dan *Moving Average*. ARMA merupakan penggabungan dari metode *moving average* dan metode *autoregressive* yakni suatu metode peramalan data runtun waktu yang memanfaatkan data historis dan data sekarang untuk menghasilkan peramalan jangka pendek yang akurat (Hutasuhut, Anggraeni, & Tyasnurita, 2014). Kemudian terdapat metode ARIMA yakni serupa dengan metode ARMA namun yang menjadi pembedanya adalah diferensiasinya. Metode ARMA digunakan untuk meramalkan data stasioner, sedangkan metode ARIMA ini dapat digunakan pada semua pola data, termasuk data yang tidak stasioner, namun perlu dilakukan adanya diferensiasi agar data stasioner. Jika data sudah stasioner maka peramalan dilakukan dengan metode ARMA, namun jika belum stasioner perlu dilakukan diferensiasi, yakni mengacu pada metode ARIMA. Pada metode ARIMA ini, model yang digunakan harus memenuhi seluruh asumsinya. Pada prakteknya, perhitungan ARMA sering kali diperlakukan sebagai model ARIMA karena pada data tidak membutuhkan proses pembedaan (*differencing*) karena sudah stasioner, sehingga model ARMA sering dituliskan sebagai model ARIMA ( $p, 0, q$ ) atau ARMA( $p, q$ ). Perbedaan ARMA dan ARIMA hanya terletak pada proses diferensiasinya saja.

Selain metode ARMA, terdapat metode peramalan lain yang dapat digunakan adalah metode *extreme learning machine* (ELM). Metode ELM merupakan metode diperkenalkan oleh Huang pada tahun 2004. ELM merupakan metode pengembangan dari jaringan syaraf tiruan *feedforward* sederhana dengan menggunakan satu hidden layer atau biasa dikenal dengan *Single Hidden Layer Feedforward Neural Networks* (SLFNs) yang dikenal dengan metode *speed learning* dan tidak membutuhkan adanya asumsi khusus. Pada ELM ini *input weight* nilainya acak, sehingga meminimalisir terjadinya prediksi yang tidak stabil.

Metode ELM memiliki 5 tahapan yaitu normalisasi data, proses *training*, proses *testing*, denormalisasi data, dan mencari nilai *Mean Absolute Percentage*

*Error* (MAPE) untuk mengukur tingkat kesalahan (Giusti, Widodo, & Adinugroho, 2018).

Dari kedua metode ini antara ARMA dan metode ELM akan dibandingkan dan metode mana yang lebih baik untuk digunakan dalam meramalkan jumlah buruh pabrik yang mampu terserap di PT. Boyang Industrial karena kedua metode ini memiliki keunggulan masing-masing untuk mendapatkan hasil prediksi dengan nilai MAPE paling rendah.

Berdasarkan latar belakang tersebut, peneliti akan melakukan penelitian tentang perbandingan prediksi jumlah buruh pabrik yang mampu terserap menggunakan metode *Autoregressive Moving Average* (ARMA) dan metode *Extreme Learning Machine* (ELM) untuk memperoleh metode peramalan dengan nilai MAPE terkecil.

## **1.2. Rumusan Masalah**

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

1. Bagaimana gambaran umum Data Jumlah Buruh Pabrik di PT. Boyang Industrial 2016-2021?
2. Bagaimana hasil perbandingan metode *Autoregressive Moving Average* (ARMA) dan *Extreme Learning Machine* (ELM) pada hasil peramalan Jumlah Buruh Pabrik di PT. Boyang Industrial tahun 2022?

## **1.3. Batasan Masalah**

Batasan masalah digunakan untuk menghilangkan terjadinya penyimpangan dalam penelitian. Adapun batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Data yang digunakan dalam penelitian ini adalah data Jumlah Buruh Pabrik di PT. Boyang Industrial pada Januari 2016 hingga Desember 2021 dengan data periode bulanan.
2. Metode analisis yang digunakan adalah *Autoregressive Moving Average* (ARMA) dan *Extreme Learning Machine* (ELM).
3. Menggunakan nilai *Mean Absolute Percentage Error* (MAPE) untuk menentukan metode terbaik.

#### **1.4. Tujuan Penelitian**

Tujuan dari penelitian ini adalah sebagai berikut:

1. Mengetahui gambaran umum jumlah buruh pabrik yang terserap di PT. Boyang Industrial pada Januari 2016 sampai Desember 2021.
2. Mengetahui hasil peramalan jumlah buruh pabrik yang terserap di PT. Boyang Industrial tahun 2022 dengan metode terbaik.

#### **1.5. Manfaat Penelitian**

Manfaat dari penelitian ini adalah sebagai berikut:

1. Bagi PT. Boyang Industrial  
Penelitian ini akan membantu PT. Boyang Industrial dalam memprediksi jumlah buruh yang masuk dan keluar tiap bulannya, karena jumlah buruh mempengaruhi jumlah rambut palsu yang di produksi, sehingga perlu adanya prediksi jumlah buruh supaya tiap buruh dapat memproduksi rambut palsu dengan maksimal.
2. Bagi Penelitian Lanjutan  
Penelitian ini sebagai referensi untuk penelitian selanjutnya serta menambah wawasan penulis dan pembaca mengenai metode *Autoregressive Moving Average* dan *Extreme Learning Machine*.
3. Bagi Mahasiswa  
Penelitian ini akan memperluas wawasan dan pengetahuan khususnya tentang metode penelitian ini dalam memprediksi jumlah buruh pabrik yang terserap di PT. Boyang Industrial.

## BAB II

### TINJAUAN PUSTAKA

#### 2.1. *Autoregressive Integrated Moving Average*

Penelitian yang dilakukan oleh (Firman, Arifin, & Hatta, 2019) yang berawal untuk memecahkan masalah yakni terdapat permasalahan di Kota Samarinda yaitu banyak yang belum mendapatkan pekerjaan, maupun banyak yang bekerja namun belum sesuai minatnya. Tujuan dari penelitian ini adalah untuk membuat sistem yang meramalkan angka pencari kerja untuk masa yang akan datang dengan metode ARIMA. Peneliti menggunakan data pencari kerja dari tahun 2014 hingga 2018. Pada sistem ini, metode ARIMA memberikan hasil yang sangat baik dengan tingkat kesalahan terkecil di tiap modelnya, berdasarkan akurasi peramalan untuk 1 periode selanjutnya di tiap tingkat pendidikan pencari kerja terdaftar Kota Samarinda.

Peramalan jumlah penduduk di Kabupaten Semarang dilakukan oleh (Sari & Mahatma, 2021) Peramalan jumlah penduduk ini sangat penting untuk pengkajian mengenai pembangunan daerah. Penelitian ini menggunakan data sekunder jumlah penduduk Kabupaten Semarang tahun 1989 sampai 2019. Pada penelitian ini didapatkan model ARIMA(2, 1, 1) dengan telah memenuhi seluruh uji asumsinya. Dengan persamaan  $X_t = X_{t-1} + \phi_1 X_{t-1} - \phi_1 X_{t-2} + \phi_2 X_{t-2} - \phi_2 X_{t-3} + e_t - \theta_1 e_{t-1}$  untuk meramalkan tahun 2020 hingga 2025.

Diperlukan adanya prediksi untuk memprediksi tingkat pengangguran untuk Langkah pengkajian dan preventif lainnya Penelitian tentang prediksi tingkat pengangguran tersebut dilakukan oleh (Juarna & Sulaiman, 2021). Data yang digunakan adalah data pengangguran tahun 2005 sampai dengan tahun 2019. Hasil peramalan yang didapatkan adalah dengan menggunakan ARIMA (0, 1, 12) dengan nilai RMSE = 1,01, nilai MSE = 1,0201, sedangkan dengan metode *Holt-Winters* didapatkan nilai RMSE = 0,45 dan MSE = 0,2025. Kesimpulan dari hasilnya bahwa metode *Holt-Winters* adalah metode terbaik dalam meramalkan tingkat pengangguran di Indonesia ini.

Penelitian tentang peramalan jumlah mahasiswa baru dilakukan oleh (Jamila, Siregar, & Yunis, 2021). Peramalan ini dianggap penting bagi perguruan tinggi supaya lebih optimal dalam pelayanan dan lainnya. Pada peramalan ini menggunakan data penerimaan mahasiswa baru dari 2010 hingga 2019 di suatu

Universitas. Didapatkan model yang signifikan menggunakan ARIMA(2, 1, 1) untuk meramalkan jumlah penerimaan mahasiswa 5 tahun kedepan. Didapatkan MAPE sebesar 7,06% yang berarti tingkat akurasi sebesar 93%. Membuktikan bahwa peramalan ini sangat akurat.

Penelitian yang telah dilakukan oleh (Aditya, Maesyaroh, Tanjung, & Remayasari, 2021) meneliti tingkat pengangguran saat masa pandemi Covid-19. Untuk memperoleh prediksi yang akurat dalam jangka waktu yang pendek, peneliti menggunakan metode ARIMA. Prediksi pada penelitian kali ini menggunakan ARIMA(1, 1, 0). Yang berarti terdapat penambahan tingkat pengangguran tiap tahunnya di Indonesia selama 4 tahun kedepan. Efek pandemic ini jika berlangsung Panjang akan meningkatkan jumlah pengangguran.

Penelitian tentang peramalan klaim program jaminan hari tua pada ketenagakerjaan di Kota Langsa ini dilakukan oleh (Saumi & Amalia, 2020). Penelitian ini berkaitan dengan BPJS Ketenagakerjaan yaitu BPJS sendiri memiliki program untuk melindungi ketidakpastian yang terjadi pada para pekerja, contohnya kecelakaan saat kerja. Peneliti menggunakan data klaim BPJS ketenagakerjaan jaminan hari tua pada Januari 2014 – Juli 2019. Klaim ini berfluktuasi mengalami peningkatan dan penurunan pada periode Agustus 2019-Desember 2019. Model ARIMA yang cocok dan tepat adalah ARIMA(4, 1, 2) dengan nilai MAPE terendah yaitu 6,87%.

## **2.2. *Autoregressive Moving Average***

Penelitian yang meramalkan inflasi di Indonesia untuk periode ke depan dengan menggunakan metode ARMA dilakukan oleh (Melyani, Nurtsabita, Shafa, & Widodo, 2021). Dari penelitian ini didapatkan bahwa metode ARMA(3, 0, 0) menghasilkan nilai AIC dan RMSE paling kecil, dan menghasilkan hasil peramalan angka inflasi untuk Januari sampai Desember 2021 dengan angka 0,1%-0,3%.

Penerapan Metode ARMA dalam Peramalan Jumlah Pelanggan Internet di Surabaya dilakukan oleh (Hendriyanto & Sutanto, 2018) mendapatkan hasil bahwa model ARMA(1, 0, 0) model yang memiliki keakuratan cukup untuk mengestimasi pelanggan wifi internet PT. Exas.

Penelitian tentang Perbandingan Model AR(1), ARMA (1, 1), dan ARIMA(1, 1, 1) yang dilakukan oleh (Vulandari & Parwitasari, 2018) untuk memprediksi tinggi muka air sungai Bengawan Solo berdasarkan perbandingan nilai MAPE ketiga model nilai terendah adalah model ARMA(1, 1), yaitu 0,668384.

Penelitian yang digunakan untuk memodelkan data penjualan mobil dengan ARMA dengan metode Bayesian yang dilakukan oleh (Pawestri, Setiawan, & Lilik, 2019) diperoleh model Autoregressive 1 (AR 1) Musiman dengan komponen yang merupakan bagian dari model ARMA. Pemodelan data dilakukan untuk mengetahui apakah data dapat diestimasi dengan metode bayesian *dengan model*  $y_t = 30,9238 + 0,4439y_{t-12} + \varepsilon_t$ .

Penelitian menggunakan metode ARMA yang dilakukan oleh (Desvina & Yuliasari, 2020) terhadap nilai indeks harga saham syariah. Penelitian ini menggunakan data yang diambil bulan Mei 2018 sampai November 2018. Hasil peramalan menunjukkan bahwa terjadi penurunan jika dibandingkan pada bulan-bulan sebelumnya dan polanya sama dengan data aktual yaitu tren, dengan nilai MAPE 0,01163%.

Penelitian metode *Box-Jenkins* dengan ARMA (1, 2) yang dilakukan oleh (Desvina, Khusnihita, & Rahmadeni, 2020) digunakan untuk memprediksi penyakit ISPA tahun 2014 hingga tahun 2019, model ARMA(1, 2) dengan nilai MAPE 1,38% merupakan model paling cocok untuk meramalkan jumlah kasus penyakit ISPA.

### **2.3. Extreme Learning Machine**

Penelitian yang telah dilakukan oleh (Adrian, Rismawan, & Midyanti, 2019) bertujuan untuk meramalkan kepadatan penduduk di Kalimantan Barat sebagai acuan, karena pertumbuhan penduduk yang tak terkendali adalah salah satu penyebab meningkatnya kemiskinan, kriminalitas, dan keterbatasan ruang. Pengujian dengan jumlah hidden neuron 5, 10, 15 hingga 100. Didapatkan nilai MAPE terkecil ketika menggunakan *hidden neuron* sejumlah 30, yaitu sebesar 3,67%.

(Prianda & Widodo, 2021 ) melakukan peramalan dengan metode ELM dan Metode Seasonal ARIMA pada Peramalan Jumlah Mancanegara ke Bali. Dengan

menggunakan data runtun waktu wisatawan mancanegara pada tahun 2014 hingga 2019. Berdasarkan hasil penelitian, didapatkan nilai MAPE dari kedua metode berada dibawah 10% yakni mengartikan bahwa metode tersebut menghasilkan peramalan yang sangat baik. Dari metode SARIMA didapatkan MAPE sebesar 4,97% sedangkan metode ELM memiliki nilai MAPE lebih besar 7,62%. Wisatawan mancanegara diprediksi meningkat 5,3% dari tahun sebelumnya.

Penelitian tentang prediksi jumlah kunjungan wisatawan mancanegara di Singapura dengan metode *Extreme Learning Machine* oleh (Libianto, Tibyani, & Sari, 2019) Kunjungan wisatawan mancanegara di Singapura mengalami peningkatan signifikan dari tahun 2015 hingga 2016. Dilakukan uji 10 kali dengan menggunakan 84 *dataset*. Pada hasil penelitian, didapatkan nilai MAPE terkecil sebesar 7,41% dengan jumlah *hidden neuron* sebanyak 10. Dengan pembagian 80% data *training* dan 20% data *testing*. Dapat disimpulkan bahwa metode ELM memberikan prediksi yang sangat baik karena nilai MAPE dibawah 10%.

(Saputri & Ekojono, 2018) meramalkan volume impor beras dengan metode *Extreme Learning Machine*. Peneliti mengatakan bahwa impor beras terjadi ketika kebutuhan beras di negeri ini lebih besar daripada produksinya. Peneliti menggunakan 4 kali percobaan dengan data *training* 50%, 60%, 70% dan 80%. Jumlah data *training* ini mempengaruhi hasil peramalannya. Hasil peramalan terbaik didapatkan dengan data training sebesar 80%. Dengan nilai rata-rata *error* 0,0152.

Penelitian menggunakan metode ELM yang dilakukan oleh (Agasta, Cholissodin, & Ratnawati, 2018) dengan topik jumlah produksi kelapa sawit di PT. Sandabi Indah Lestari Kota Bengkulu. Penelitian ini menggunakan data produksi tahun 2015 hingga 2017 yang totalnya ada 297 data dengan pembagian 80% untuk data training dan 20% data testing. Dengan menggunakan 2 buah *neuron* sampai 15 buah *neuron*. Peneliti menguji 2 kali, pola 2 hasil MAPE lebih besar daripada pola 1. Yaitu MAPE pola 1 19,19% sedangkan nilai MAPE pada pola 2 yaitu 28,16%. Dengan fitur tersebut diperoleh nilai rata-rata MAPE yaitu 20,19% yang tergolong masih dalam kategori yang baik.

Penelitian yang dilakukan oleh (Kertayuga, Santoso, & Hidayat, 2021) untuk memprediksi nilai ekspor impor migas dan non migas dengan metode ELM.

Penelitian ini dilakukan karena peneliti tertarik dengan ekspor impor karena ekspor impor ini merupakan roda perekonomian bagi Negara Indonesia. Peneliti menggunakan data dari BPS tahun 1993 sampai 2020. Dengan menggunakan perbandingan 80% dan 20% untuk pembagian *training testing*, dan jumlah *hidden neuron* sebanyak 10 buah dengan nilai MAPE sebesar 10,0515%.



**Tabel 2. 1** Perbandingan dengan Penelitian Sebelumnya

No	Penulis	Judul Penelitian	Tahun	Metode	Persamaan	Perbedaan
1	Firman, Arifin, Z., & Hatta, H. R.	Sistem Peramalan Kesempatan Kerja Terhadap Pencari Kerja Terdaftar Dengan Metode Arima Pada Kota Samarinda	2019	ARIMA	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data pencari kerja</li> <li>- Penelitian yang terdahulu memiliki <i>output</i> yaitu sebuah sistem</li> </ul>
2	Sari, E. N., & Mahatma, T.	Peramalan Jumlah Penduduk Kabupaten Semarang dengan Metode Box-Jenkins	2021	ARIMA	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data penduduk Kabupaten Semarang</li> <li>- Diperoleh model ARIMA(2, 1, 1) Penelitian terdahulu, diperoleh</li> </ul>

						model ARIMA(2, 0, 1) pada penelitian ini
3	Juarna, A., & Sulaiman, A.	Peramalan Tingkat Pengangguran di Indonesia Menggunakan Metode Time Series dengan Model ARIMA dan Holt-Winters	2021	ARIMA dan <i>Holt Winters</i>	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan jumlah pengangguran</li> <li>- Penelitian yang dilakukan membandingkan metode ARIMA dan ELM, penelitian terdahulu membandingkan metode ARIMA dan <i>Holt Winters</i></li> </ul>
4	Jamila, A. U., Siregar, B. M., & Yunis, R.	Analisis Runtun Waktu Untuk Memprediksi Jumlah Mahasiswa Baru Dengan Model Arima.	2021	ARIMA	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data jumlah mahasiswa</li> </ul>

						- Diperoleh model ARIMA(2, 1, 1) Penelitian terdahulu, diperoleh model ARIMA(2, 0, 1) pada penelitian ini
5	Aditya, D., Maesyaroh, W. U., Tanjung, I. R., & Remayasari, M.	Kondisi Tingkat Pengangguran di Indonesia pada Masa Pandemi Covid-19 : Studi Kasus dengan Pendekatan Metode Arima	2021	ARIMA	Metode sama	- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data jumlah pengangguran - Diperoleh model ARIMA(1, 1, 0) Penelitian terdahulu, diperoleh model ARIMA(2, 0, 1) pada penelitian ini
6	Saumi, F., & Amalia, R.	Penerapan Model Arima untuk Peramalan Jumlah Klaim Program Jaminan Hari Tua pada	2020	ARIMA	Metode sama	- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian

		BPJS Ketenagakerjaan Kota Langsa.				<p>terdahulu menggunakan data klaim program jaminan hari tua.</p> <ul style="list-style-type: none"> <li>- Diperoleh model ARIMA(4, 1, 2)</li> </ul> <p>Penelitian terdahulu, diperoleh model ARIMA(2, 0, 1) pada penelitian ini</p>
7	Adrian, S. Y., Rismawan, T., & Midyanti, D.	Penerapan Metode Extreme Learning Machine untuk Peramalan Jumlah Kepadatan Penduduk di Kalimantan Barat.	2019	ELM	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data kepadatan penduduk</li> <li>- Penelitian ini hanya menggunakan nilai MAPE, penelitian terdahulu menggunakan nilai MAPE dan MSE untuk menentukan peramalan terbaik.</li> </ul>

						- Penelitian ini menggunakan 8 <i>hidden layer</i> , penelitian terdahulu menggunakan 30 <i>hidden layer</i> .
8	Prianda, B. G., & Widodo, E.	Perbandingan Metode Seasonal ARIMA dan Extreme Learning Machine pada Peramalan Jumlah Wisatawan Mancanegara ke Bali.	2021	ELM dan SARIMA	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data wisatawan mancanegara</li> <li>- Penelitian yang dilakukan membandingkan metode ARIMA dan ELM, penelitian terdahulu membandingkan metode SARIMA dan ELM</li> <li>- Penelitian ini menggunakan 8 <i>hidden layer</i>, penelitian terdahulu menggunakan 54 <i>hidden layer</i>.</li> </ul>

9	Libianto, M. S., Tibyani, & Sari, Y. A.	Prediksi Jumlah Kunjungan Wisatawan Mancanegara Pada Negara Singapura Menggunakan Algoritme Extreme Learning Machine	2019	ELM	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data wisatawan mancanegara</li> <li>- Penelitian ini menggunakan 8 <i>hidden layer</i>, penelitian terdahulu menggunakan 10 <i>hidden layer</i>.</li> </ul>
10	Saputri, E. A., & Ekojono.	Prediksi Volume Impor Beras Nasional Menggunakan Jaringan Saraf Tiruan Metode ELM (Extreme Learning Machine)	2018	ELM	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data volume impor beras.</li> <li>- Penelitian ini menggunakan 8 <i>hidden layer</i>, penelitian terdahulu menggunakan 7 <i>hidden layer</i>.</li> </ul>

11	Agasta, E., Cholissodin, I., & Ratnawati, D. E.	Prediksi Jumlah Produksi Kelapa Sawit Dengan Menggunakan Metode Extreme Learning Machine (ELM) (Studi kasus: PT. Sandabi Indah Lestari Kota Bengkulu).	2018	ELM	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data produksi kelapa sawit.</li> <li>- Penelitian ini menggunakan 8 <i>hidden layer</i>, penelitian terdahulu menggunakan 13 <i>hidden layer</i>.</li> </ul>
12	Kertayuga, D., Santoso, E., & Hidayat, N.	Prediksi Nilai Ekspor Impor Migas Dan Non- Migas Indonesia Menggunakan Extreme Learning Machine (ELM).	2021	ELM	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data nilai ekspor impor migas dan non migas.</li> </ul>
13	Melyani, C.A., & dkk.	Peramalan Inflasi di Indonesia menggunakan Metode	2021	ARMA	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang</li> </ul>

		Autoregressive Moving Average				Industrial, sedangkan penelitian terdahulu menggunakan data Inflasi - Diperoleh model ARMA(3, 0, 0) Penelitian terdahulu, diperoleh model ARMA(2, 0, 1) pada penelitian ini
14	Hendriyanto, R., & Sutanto, H.T.	Penerapan Model ARMA dalam Peramalan Jumlah Pelanggan Internet di Surabaya	2018	ARMA	Metode sama	- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data pelanggan internet. - Diperoleh model ARMA(1, 0, 0) Penelitian terdahulu, diperoleh model ARMA(2, 0, 1) pada penelitian ini
15	Vulandari, R.T., & Parwitasari, T.A.	Perbandingan Model AR(1), ARMA(1, 1), dan ARIMA(1, 1, 1) pada Prediksi Tinggi	2018	AR, ARMA, ARIMA	Metode sama	- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang



		Muka Air Sungai Bengawan Solo pada Pos Pemantauan Jurug.				Industrial, sedangkan penelitian terdahulu menggunakan data tinggi muka air. - Diperoleh model ARMA(1, 0, 1) Penelitian terdahulu, diperoleh model ARMA(2, 0, 1) pada penelitian ini - Penelitian saat ini membandingkan 2 metode, penelitian terdahulu membandingkan 3 metode.
16	Pawestri, V., Setiawan, A., & Linawati, L.	Pemodelan Data Penjualan Mobil Menggunakan Model <i>Autoregressive Moving Average</i> Berdasarkan Metode Bayesian	2019	ARMA	Metode sama	- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data penjualan mobil. - Metode ARMA berdasarkan bayesian

17	Desvina, A.P., & Yuliasari, F.	Peramalan Nilai Indeks Harga Saham Syariah Menggunakan Metode Box-Jenkins	2020	ARMA	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data HIS Syariah.</li> <li>- Diperoleh model ARMA(1, 0, 1) Penelitian terdahulu, diperoleh model ARMA(2, 0, 1) pada penelitian ini</li> </ul>
18	Desvina, A.P., Khusnihita, R., & Rahmadeni.	Apikasi Metode Box- Jenkins untuk Memprediksi Jumlah Kasus Penyakit ISPA di RSUD Arifin Achmad Provinsi Riau	2020	ARMA	Metode sama	<ul style="list-style-type: none"> <li>- Studi kasus yang digunakan berbeda, penelitian ini menggunakan data jumlah buruh pabrik di PT. Boyang Industrial, sedangkan penelitian terdahulu menggunakan data jumlah kasus penyakit ISPA.</li> <li>- Diperoleh model ARMA(1, 0, 2) Penelitian terdahulu, diperoleh</li> </ul>

						model ARMA(2, 0, 1) pada penelitian ini
--	--	--	--	--	--	---

## BAB III LANDASAN TEORI


### 3.1. Rambut Palsu

Wig merupakan sebuah rambut palsu yang dibuat untuk menutupi kepala dari kebotakan maupun untuk *fashion*. Pemakaian wig atau rambut palsu ini ditujukan untuk menambah kepercayaan diri penggunanya. Berdasarkan bahan dasarnya, wig terdiri dari 2 jenis, yaitu wig yang berbahan dasar rambut manusia asli atau biasa disebut *human hair* dan wig yang berbahan dasar sintetis dari plastik.

### 3.2. Alopecia Areata

Terdapat 2 faktor penggunaan wig, yang pertama faktor estetika, dan yang kedua faktor medis, misalnya digunakan oleh seseorang yang mengalami kebotakan karena efek samping kemoterapi, atau digunakan oleh orang-orang dengan kondisi *Alopecia areata*. *Alopecia areata* adalah kondisi dimana seseorang mengidap autoimun kronis yang menyebabkan kebotakan. Penyakit ini menyerang folikel rambut yang menyebabkan rambut rontok dan menyebabkan kebotakan (Darwin, 2018). Penderita *Alopecia areata* akan kehilangan rambutnya atau mengalami kerontokan rambut secara tiba-tiba.

Rambut palsu merupakan tingkat 4 dalam menghadapi kasus *alopecia areata*. Rambut palsu, jilbab, dan topi adalah yang biasa digunakan penderita untuk menutupi penyakit *Alopecia areata* yang dialami mereka (Ardhaninggar & Rahmadewi, 2018).



**Gambar 3. 1** Tipe dari *Alopecia Areata*

Sumber: (D&PS Magazine for Dermatologist & Plastic Surgeons, 2020)

### **3.3. Buruh Pabrik**

Menurut UU No 13 Tahun 2003, tenaga kerja adalah orang yang melakukan pekerjaan untuk menciptakan suatu barang maupun jasa untuk memenuhi kebutuhan sendiri dan untuk orang lain. Secara pengertian buruh merupakan orang yang bekerja orang yang bekerja untuk orang lain yang dibayar oleh orang yang mempekerjakan mereka.

### **3.4. Ekspor**

Pengertian Ekspor yang dipandang dari sudut pandang bahasa Indonesia merupakan perbuatan mengirimkan barang ke luar negeri atau luar Indonesia (Sutedi, 2014). Menurut Undang-Undang Republik Indonesia Pasal 14 Nomor 10 Tahun 1995 ekspor merupakan kegiatan mengeluarkan barang dari daerah pabean. Pada penelitian ini, ekspor yang dilakukan adalah ekspor rambut palsu dari Indonesia ke berbagai benua, seperti Asia dan Eropa.

### **3.5. Statistika Deskriptif**

Metode statistik terbagi menjadi dua, yaitu statistika deskriptif dan statistik inferensial. Metode statistik itu sendiri merupakan metode yang digunakan untuk melakukan pengumpulan data, penyajian data, analisis dan interpretasi data. Statistik deskriptif hanya tentang memberikan keterangan informasi mengenai suatu data. (Nasution L. M., 2017). Menurut (Sholikhah, 2016) statistik deskriptif adalah statistik yang digunakan untuk menganalisis data, angka, agar dapat memberikan gambaran yang ringkas, dan jelas, sehingga dapat diambil kesimpulannya.

Yang perlu disajikan pada statistika deskriptif ada 2 yaitu pemusatan data, dan yang kedua adalah penyebaran data. Berikut merupakan penjelasannya:

#### **1. Ukuran Pemusatan Data**

Ukuran pemusatan data atau tendensi sentral merupakan ringkasan deskriptif kumpulan data melalui nilai yang mencerminkan sebaran data tersebut. Ukuran ini mampu mewakili dari jumlah semua data. Jenis-jenis ukuran pemusatan data contohnya ada *mean* (rata-rata), *median* (nilai tengah), *modus* (nilai yang paling sering muncul).

## 2. Ukuran Penyebaran Data

Sementara itu untuk pengertian ukuran penyebaran data menyatakan seberapa besar penyimpangan data terhadap ukuran pemusatannya. Ukuran penyebaran data contohnya adalah standar deviasi, variansi, dan kuartil.

### 3.6. *Forecasting*

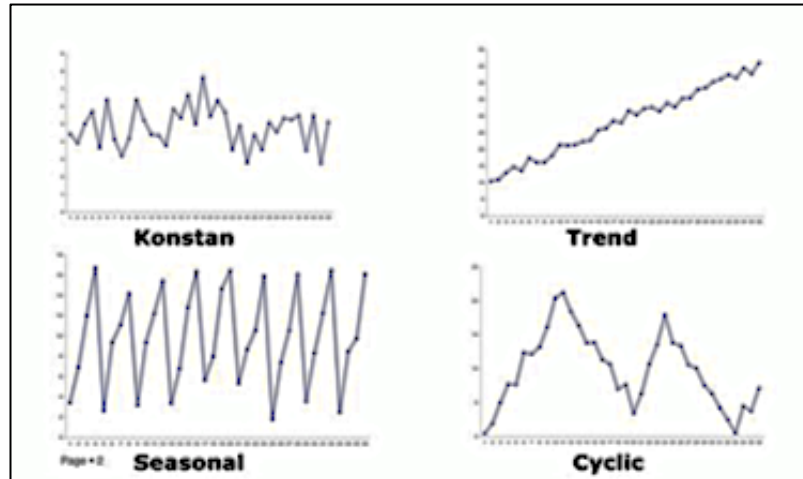
Pengertian *forecasting* atau peramalan adalah ilmu untuk memprediksi peristiwa di masa depan dengan menggunakan data historis dan memproyeksikannya ke masa depan dengan pendekatan sistematis.

*Forecasting* dapat dilakukan oleh segala bidang, baik itu pemerintahan atau instansi, perusahaan, maupun masyarakat umum. Di bidang perusahaan, *forecasting* adalah hal penting yang dapat mempengaruhi pengambilan keputusan. *Forecasting* dapat menjadi dasar untuk perencanaan jangka panjang (Nurlifa & Kusumadewi, 2017).

Salah satu manfaat *forecasting* atau peramalan bagi suatu perusahaan adalah untuk memprediksi keuntungan yang akan datang. *Forecasting* juga bisa digunakan untuk memprediksi jumlah barang yang laku terjual serta memprediksi bahan baku yang digunakan, supaya pada saat proses produksi tidak terjadi kelebihan maupun kekurangan bahan produksi agar suatu industri tersebut mengambil kebijakan yang efektif serta efisien.

### 3.7. *Time Series*

Data *time series* atau data runtun waktu adalah sekumpulan data yang diamati selama periode waktu tertentu. Data *time series* ini digunakan sebagai gambaran di masa lalu dan digunakan sebagai prediksi di masa yang akan datang. Data yang diamati serta dikumpulkan secara berkala berdasarkan urutan waktunya, bisa berupa jam, hari, minggu, bulan atau tahun.



**Gambar 3. 2** Pola data *Time Series*

Sumber: (Prakoso, B.H., 2019)

Terdapat 4 pola data *time series*, berikut merupakan pola datanya:

1. Pola Konstan/*Horizontal*

Nilai dari data *time series* cenderung konstan walaupun terjadi kenaikan maupun penurunan nilai, namun data yang ada cenderung berfluktuasi dekat dengan nilai rata-ratanya. Contohnya yaitu penjualan produk yang tidak meningkat ataupun menurun selama kurun waktu tertentu.

Pola *Trend*

Nilai dari data *time series* untuk pola data *trend* cenderung mengalami peningkatan ataupun penurunan selama kurun waktu tertentu yang diamati. Contohnya kenaikan pada harga emas di Indonesia 5 tahun terakhir dari tahun 2017 sampai 2022.

2. Pola *Seasonal*/Musiman

Pada pola data *seasonal* atau musiman, nilai data *time series* terjadi fluktuasi yang tergantung pada musim atau periode tertentu secara berulang. Pola ini biasanya terbentuk karena suatu musim tertentu seperti contohnya penjualan kambing dan sapi saat waktu idhul adha akan berbeda dengan penjualan kambing dan sapi saat waktu lainnya.

3. Pola *Cyclic*/Siklis

Pola dimana data *time series* mengalami fluktuasi atau peningkatan dan penurunan dengan rentang waktu yang panjang dan tidak memiliki pola tertentu. Pola ini juga biasa disebut dengan pola musiman jangka panjang. Durasinya lama, bisa lebih dari satu tahun. Contohnya penjualan

yang dipengaruhi fluktuasi ekonomi jangka panjang seperti yang berhubungan dengan bisnis (Prakoso, 2019).

### 3.8. Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF)

Autokorelasi merupakan suatu keadaan dimana residual suatu pengamatan berkorelasi dengan residual pengamatan lainnya. ACF berfungsi untuk mengidentifikasi stasioneritas data runtun waktu, selain itu ACF juga digunakan untuk menentukan parameter dari MA (*Moving Average*). Nilai koefisien ACF yang melebihi interval batas yang dapat diterima digunakan untuk menentukan model dari MA (q). Nilai ACF secara manual dapat dihitung dengan rumus sebagai berikut:

$$\rho_k = \frac{\sum_{t=1}^{n-k} (Z_t - \mu)(Z_{t+k} - \mu)}{\sum_{t=1}^n (Z_t - \mu)^2} \quad (3.1)$$

dengan:

- $\rho_k$  : Koefisien ACF
- $Z_t$  : Data pada waktu ke-t
- $Z_{t+k}$  : Data pada waktu ke-t+k
- $\mu$  : Rata-rata data
- $k$  : Waktu periode *time series*

**Contoh:**

**Diketahui:**

**Tabel 3. 1** Contoh Mencari Nilai ACF Lag 1

t	$Z_t$	$Z_{t+k}$ (lag1)	$(Z_t - \mu)$	$(Z_{t+k} - \mu)$	$(Z_t - \mu)(Z_{t+k} - \mu)$	$(Z_t - \mu)^2$
1	50	51	-6,5	-5,5	35,75	42,25
2	51	53	-5,5	-3,5	19,25	30,25
3	53	56	-3,5	-0,5	1,75	12,25
4	56	57	-0,5	0,5	-0,25	0,25
5	57	60	0,5	3,5	1,75	0,25
6	60	62	3,5	5,5	19,25	12,25
7	62	59	5,5	2,5	13,75	30,25
8	59	54	2,5	-2,5	-6,25	6,25
9	54	63	-2,5	6,5	-16,25	6,25



10	63	0	6,5	0	0	42,25
Jumlah					68,75	182,5

**Tabel 3. 2** Contoh Mencari Nilai ACF Lag 2

t	$Z_t$	$Z_{t+k}$ (lag2)	$(Z_t - \mu)$	$(Z_{t+k} - \mu)$	$(Z_t - \mu)(Z_{t+k} - \mu)$	$(Z_t - \mu)^2$
1	50	53	-6,5	-3,5	22,75	42,25
2	51	56	-5,5	-0,5	2,75	30,25
3	53	57	-3,5	0,5	-1,75	12,25
4	56	60	-0,5	3,5	-1,75	0,25
5	57	62	0,5	5,5	2,75	0,25
6	60	59	3,5	2,5	8,75	12,25
7	62	54	5,5	-2,5	-13,75	30,25
8	59	63	2,5	6,5	16,25	6,25
9	54	0	-2,5	0	0	6,25
10	63	0	6,5	0	0	42,25
Jumlah					36	182,5

**Ditanya:**

Nilai ACF untuk lag 1 dan lag 2?

**Jawab:**

$$\rho_1 = \frac{68,75}{182,5} = 0,376$$

$$\rho_2 = \frac{36}{182,5} = 0,197$$

Kemudian PACF digunakan secara bersama untuk mengidentifikasi model ARMA dari suatu data *time series* untuk menentukan parameter dari *Autoregressive* (AR). Nilai koefisien PACF yang melebihi interval batas yang dapat diterima pada lag-p dapat digunakan untuk menentukan model dari proses AR (p) (Firman, Arifin, & Hatta, 2019). PACF digunakan untuk mengukur tingkat keeratan antara  $Z_t$  dan  $Z_{t-k}$ , dengan asumsi pengaruh *time lag* 1,2,3,..., dan seterusnya sampai  $k - 1$  dianggap terpisah.

Berikut Rumus PACF manual adalah:

$$\phi_{k,k} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j} \quad (3.2)$$

dengan:

$\phi_{k,k}$  = Koefisien ACF

$\rho_{k-j}$  = Koefisien ACF pada waktu  $(k-j)$  ;  $k=1,2,\dots,n; j=1,2,\dots,(k-1)$

**Contoh:**

**Diketahui:**

Nilai ACF pada lag 1 = 0,376

Nilai ACF pada lag 2 = 0,197

**Ditanya:**

Nilai PACF lag 1 dan lag 2?

**Jawab:**

$$\phi_{1,1} = \rho_1$$

$$\phi_{1,1} = 0,376$$

$$\phi_{2,2} = \frac{\rho_2 - \phi_{1,1} \rho_1}{1 - \phi_{1,1} \rho_1}$$

$$\phi_{2,2} = \frac{0,197 - (0,376 \times 0,376)}{1 - (0,376 \times 0,376)}$$

$$\phi_{2,2} = \frac{0,055}{0,858}$$

$$\phi_{2,2} = 0,064$$

**Jadi**, nilai PACF lag ke-1 adalah 0,376 dan nilai PACF lag ke-2 adalah 0,064, keduanya bernilai positif yang artinya batang PACF lag ke-1 dan lag ke-2 muncul ke arah atas.

### 3.9. Autoregressive (AR)

AR adalah model yang menjelaskan variabel dependen yang dipengaruhi oleh variabel itu sendiri pada periode masa lampau. Model AR(p) atau ARIMA (p, 0, 0) dengan persamaan modelnya adalah:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t \quad (3.3)$$

dengan,

$X_t$  : nilai variabel X pada waktu ke-t

$\phi_p$  : parameter autoregressive ke-p

$e_t$  : nilai error pada saat ke-t

### 3.10. *Moving Average (MA)*

MA (Model Moving Average) adalah model yang menjelaskan hubungan ketergantungan antara nilai kesalahan yang berurutan. Model ini dinyatakan sebagai MA (q) atau model ARIMA (0, 0, q) dan bentuk persamaan modelnya adalah:

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (3.4)$$

dengan,

$X_t$  : nilai variabel X pada waktu ke-t,

$\theta_q$  : parameter moving average ke-q,

$e_t$  : nilai error pada saat ke-t.

### 3.11. *Autoregressive Moving Average (ARMA)*

ARMA

Model ARMA merupakan penggabungan model AR dan MA. Model ARIMA (p, 0, q) dengan persamaan modelnya:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (3.5)$$

dengan,

$X_t$  : nilai variabel X pada waktu ke-t,

$\phi_p$  : parameter AR ke-p,

$\theta_q$  : parameter MA ke-q,

$e_t$  : nilai error pada saat ke-t,

$e_t, e_{t-1}, e_{t-2}, \dots, e_{t-q}$ : error pada saat  $t-1, t-2, \dots, t-p$

### 3.12. *Autoregressive Integrated Moving Average (ARIMA)*

Model ARIMA(p, d, q) yang dimana orde p merupakan model AR, orde d merupakan hasil dari differensiasi, terakhir orde q menyatakan model dari MA. Bentuk umum model ARIMA adalah:

$$\phi(B)(1-B)^d X_t = \theta(B)e_t \quad (3.6)$$

dengan,

$\phi(B)$  adalah  $(1-\phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ ;  $\theta(B) = (1-\theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ ;  $\phi_i$  adalah parameter AR ke- $i$ ,  $i = 1, 2, \dots, p$ ;  $B$  adalah operator mundur ;  $d$  adalah banyaknya *differencing*;  $X_t$  adalah data aktual pada saat  $t$ ;  $\theta_j$  adalah parameter MA ke- $j$ ,  $j = 1, 2, \dots, q$ ;  $e_t$  adalah nilai kesalahan pada saat  $t$ .

**Contoh:**

**Diketahui:**

Model terbaik adalah ARIMA(2, 1, 1)

**Ditanya:**

Persamaan model untuk ARIMA(2, 1, 1)

untuk ARIMA(2, 1, 1)

**Jawab:**

$$\phi(B)(1-B)^d X_t = \theta(B)e_t \quad (3.7)$$

$$\phi(B)(1-B)^1 X_t = \theta(B)e_t$$

$$(1-\phi_1 B - \phi_2 B^2)(1-B)X_t = (1-\theta_1 B)e_t$$

$$(1-B-\phi_1 B + \phi_1 B^2 - \phi_2 B^2 + \phi_2 B^3)X_t = (1-\theta_1 B)e_t$$

$$X_t - BX_t - \phi_1 BX_t + \phi_1 B^2 X_t - \phi_2 B^2 X_t + \phi_2 B^3 X_t = e_t - \theta_1 B e_t$$

$$X_t - X_{t-1} - \phi_1 X_{t-1} + \phi_1 X_{t-2} - \phi_2 X_{t-2} + \phi_2 X_{t-3} = e_t - \theta_1 e_{t-1}$$

$$X_t = X_{t-1} + \phi_1 X_{t-1} - \phi_1 X_{t-2} + \phi_2 X_{t-2} - \phi_2 X_{t-3} + e_t - \theta_1 e_{t-1}$$

**Jadi**, model untuk ARIMA(2, 1, 1) adalah  $X_t = X_{t-1} + \phi_1 X_{t-1} - \phi_1 X_{t-2} + \phi_2 X_{t-2} - \phi_2 X_{t-3} + e_t - \theta_1 e_{t-1}$

Dengan:

$X_t$  : Prediksi bulan Januari 2022

$X_{t-1}$  : Data bulan Desember 2021

$X_{t-2}$  : Data bulan November 2021

$X_{t-3}$  : Data bulan Oktober 2021

$\phi_1$  : Parameter *Autoregressive* ke-1 atau ar.1

- $\phi_2$  : Parameter *Autoregressive* ke-2 atau ar.2  
 $\theta_1$  : Parameter *Moving average* ke-1 atau ma.1  
 $e_t$  : *Error* waktu ke-t

### 3.13. Langkah Metode ARMA

Berikut merupakan Langkah-langkahnya dalam metode ARMA:

#### 1. Identifikasi

##### a. Identifikasi Data

Saat dilakukan identifikasi data, diperlukan adanya kestasioneritasan pada rata-rata dan varians (Lailiyah, 2018). Untuk mengetahui apakah kestasioneritasan data pada rata-rata digunakan uji *Augmented Dickey Fuller* (ADF). Hipotesis awal uji ADF dapat ditulis sebagai berikut:

$H_0$  : rata-rata data tidak stasioner

$H_1$  : rata-rata data stasioner

Data runtun waktu dikatakan stasioner jika nilai mutlak ADF *test statistic* lebih besar dari nilai mutlak ADF *critical values* dengan besaran  $\alpha$  yang sudah ditentukan (Atmaja, Kencana, & Gandhiadi, 2015)

Jika data tidak stasioner maka dilakukan diferensiasi. Diferensiasi digunakan untuk mendiferensiasi data, selisih dari pengamatan yang saling berurutan dihitung untuk membentuk data *time series* yang baru (Rasyidi, 2017).

Kemudian dilakukan uji stasioneritas terhadap varians. Dikatakan stasioner terhadap varians jika dilihat dari plot Box-Cox nilai  $\lambda \geq 1$ . Jika nilai *rounded value* atau lamda ( $\lambda$ ) sama dengan 1, maka dapat dikatakan data telah stasioner dalam varians. Namun, jika lamda ( $\lambda$ ) tidak sama dengan 1 maka harus dilakukan transformasi sampai nilai *rounded value* pada Box-Cox bernilai 1. Jika data belum stasioner terhadap varians, dapat dilakukan dengan transformasi.

##### b. Identifikasi Model

Identifikasi model dilakukan dengan cara melihat pada plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) (Salwa, Tatsara, Amalia, & Zohra, 2018).

## 2. Estimasi parameter

Setelah mendapat model sementara atau model *tentative*, maka dilakukan estimasi parameter terhadap model tersebut. Pada tahap ini model diuji kelayakannya, agar nantinya didapatkan model optimal. Model optimal dilihat dari hasil tingkat signifikansi dari uji-t (Tauryawati & Irawan, 2014) atau dengan melihat *p-value* dari *R Studio*.

dengan:

### Hipotesis

$H_0$  : parameter tidak signifikan

$H_1$  : parameter signifikan

### Daerah Kritis

Tolak  $H_0$  jika  $t_{hitung} > t_{tabel}$

## 3. Uji diagnostic

Uji diagnostik dilakukan setelah menjalankan proses uji kelayakan model dengan estimasi parameter. Persyaratan untuk model peramalan yang baik adalah residualnya independen dan identik atau disebut *white noise*. Kemudian pengujian dilakukan dengan menggunakan *Ljung-box* untuk memeriksa asumsi *white noise*.

## 4. Penentuan model terbaik

Penentuan model terbaik juga dapat dilihat berdasarkan nilai kesalahan AIC atau (*Akaike Information Standard*) yang terkecil (Primandari & Kartikasari, 2020).

$$AIC = n \ln(\sigma^2) + 2(p+q+1) \quad (3.8)$$

dengan:

$p, q$  = order dari model ARMA

**Contoh:**

**Diketahui:**

**Tabel 3. 3** Contoh Mencari Nilai AIC

No	x	$x_i - \mu$	$(x_i - \mu)^2$
1	50	-6,5	42,25

2	51	-5,5	30,25
3	53	-3,5	12,25
4	56	-0,5	0,25
5	57	0,5	0,25
6	60	3,5	12,25
7	62	5,5	30,25
8	59	2,5	6,25
9	54	-2,5	6,25
10	63	6,5	42,25
	$\mu = 56,5$	jumlah	182,5

$$n = 10$$

$$\sigma^2 = \frac{182,5}{10} = 18,25$$

$$p = 2$$

$$q = 2$$


**Ditanya:** hitung nilai AIC

**Jawab:**

$$\begin{aligned}
 \text{AIC} &= n \ln(\sigma^2) + 2(p+q+1) \\
 &= 10 \ln(18,25) + 2(2+2+1) \\
 &= 10 \times 2,904 + 10 \\
 &= 39,041
 \end{aligned}$$

### 3.14. Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) merupakan sistem pemrosesan informasi yang memiliki karakteristik yang mirip dengan jaringan syaraf biologi manusia. Jaringan Syaraf tiruan dibuat sebagai generalisasi model matematis dari pemahaman manusia atau *human cognition* (Wuryandari & Afrianto, 2012). Sesuai dengan namanya yaitu jaringan syaraf tiruan, maka proses atau cara kerjanya pun sama dengan jaringan syaraf biologis. Dalam proses fungsinya jaringan syaraf tiruan ini sama jaringan syaraf biologis yang memiliki beberapa *neuron* yang saling berhubungan satu sama lain. *Neuron-neuron* ini mengirimkan informasi-informasi yang diterima oleh satu *neuron* untuk diteruskan ke *neuron* yang lainnya.



**Gambar 3. 3** Sel Syaraf Biologi  
 Sumber: Ipa area, 2015

Jaringan saraf tiruan ini memiliki 3 lapisan:

1. *Input Layer*

Lapisan pada *input layer* ini menerima input dari luar, dan nilainya mewakili sebuah data yang digunakan untuk *input-an* pada jaringan.

2. *Hidden Layer*


Lapisan ini sebagai penghubung atau perantara antara *input layer* dengan *output layer*, lapisan *hidden layer* ini merupakan bagian yang tersembunyi. Nilai dari *hidden layer* ini dapat memiliki banyak nilai.

3. *Output Layer*

Lapisan ini merupakan lapisan terakhir dari jaringan syaraf tiruan yang fungsinya untuk menempatkan keluaran atau *output* dari data yang telah dimasukkan pada jaringan ini (Badieah, Gernowo, & Surarso, 2016).

Terdapat 3 arsitektur dari jaringan syaraf tiruan, berikut merupakan arsitektur jaringan syaraf tiruan:

1. *Single Layer Network*



**Gambar 3. 4** *Single Layer Network*  
 Sumber: (Indotesis. 2012)

dengan:

$$X_1, X_i, X_n = \text{Input layer}$$

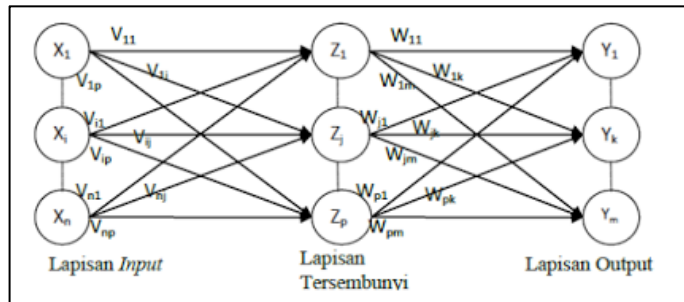


$W_{11}.. W_{mn}$  = Matriks Bobot

$Y_1, , Y_m$  = Output layer

Jaringan syaraf tiruan *single layer network* ini memiliki 1 *layer input* dan 1 *layer output*. Arsitektur pada *Single Layer Network* ini ketika mendapat *input* dan akan langsung mengeluarkan *output* tanpa harus melalui lapisan tersembunyi (*hidden layer*).

2. *Multilayer Network*



**Gambar 3. 5** *Multi Layer Network*

Sumber: (Indotesis. 2012)

dengan:

$X_1, X_i, X_n$  = Input layer

$Z_1, Z_i, Z_p$  = Hidden layer


$Y_1, Y_k$  = Output layer

$V_i$  = Matriks Bobot Pertama

$W_i$  = Matriks Bobot Kedua

Pada *Multilayer Network* ini memiliki 3 lapisan, yaitu *input layer*, *hidden layer*, dan *output layer*. Pada *Multilayer Network* ini mampu menyelesaikan masalah yang lebih rumit.

3. *Reccurent Neural Network*



**Gambar 3. 6** *Reccurent Neural Network*

Sumber: (Indotesis. 2012)

dengan:

$A_1, A_i, A_j = \text{Input layer}$


$-\epsilon = \text{Bobot acak negatif}$

*Recurrent Neural Networks* merupakan salah satu bentuk arsitektur dari jaringan syaraf tiruan yang dirancang khusus untuk memproses data yang bersambung/ berurutan. *Recurrent Neural Networks* mampu menyimpan memori atau (*feedback loop*) untuk mengenali pola data dengan baik, kemudian menggunakannya untuk membuat prediksi yang akurat.

### 3.15. *Extreme Learning Machine*

Extreme Learning Machine atau ELM pada awalnya diciptakan sebagai varian baru hasil pengembangan dari jaringan syaraf tiruan *feedforward* sederhana dengan menggunakan satu hidden layer atau biasa disebut dengan *single-hidden layer feedforward neural networks* (SLFNs). Teori pada metode *Extreme Learning Machine* atau ELM ini membuktikan bahwa *hidden layer* ini sangatlah penting dan nilai dari *hidden layer* ini bersifat acak (Bai, 2015).

Metode *Extreme Learning Machine* digunakan untuk menggeneralisasi suatu pola, metode ini memiliki kemampuan untuk menggeneralisasi dengan nilai kesalahan atau *error* yang rendah, sehingga kemampuan untuk menggeneralisasi suatu pola dapat dikatakan lebih baik. *Extreme Learning Machine* dibuat untuk mengatasi kekurangan dari jaringan syaraf tiruan *single-hidden layer feedforward neural networks* (SLFNs) dalam proses *speed learning*. Dengan pemilihan parameter seperti *input*, *weight* serta *hidden layer* secara acak sehingga kinerja pada ELM ini lebih cepat.



**Gambar 3. 7** Struktur ELM  
Sumber: (Agustina et al., 2005)

**Gambar 3.10** merupakan struktur dari *Extreme Learning Machine*, dengan :

$x_i$  = nilai *input*

$w$  = bobot *input* yang menghubungkan nilai *input* dengan *hidden layer*

$\beta$  = bobot *output* yang menghubungkan *hidden layer* dengan nilai *output*

$y_i$  = nilai *output*

Berikut merupakan tahapan dari proses pengerjaan metode *Extreme Learning Machine*:

1. Normalisasi

Tujuan dari normalisasi data ini adalah proses untuk mentransformasi data supaya nilainya berada pada rentang tertentu (Nasution, Khotimah, & Chamidah, 2019). Metode normalisasi yang digunakan adalah min-max normalization. Efisiensi dari metode jaringan syaraf tiruan sangat dipengaruhi oleh metode normalisasi yang digunakan untuk mencapai akurasi yang optimal, dan metode normalisasi yang memberikan efisiensi terbaik dari segi akurasi adalah metode *Min-max* (Chamidah, Wiharto, & Salaman, 2012).

Berikut merupakan persamaan yang digunakan untuk melakukan normalisasi data:

$$X_i' = X_{\min b} + \frac{(X_t - X_{\min})(X_{\max b} - X_{\min b})}{(X_{\max} - X_{\min})} \quad (3.8)$$

dengan:

$X_i'$  = Nilai normalisasi

$X_t$  = Nilai data aktual

$X_{\min}$  = nilai minimum data aktual

$X_{\max}$  = nilai maksimum data aktual

$X_{\min b}$  = nilai minimum data baru

$X_{\max b}$  = nilai maksimum data baru

Berikut merupakan perhitungannya:

$$\text{Data ke-1} = -0,8 + \frac{(7282 - 5608)(0,8 - (-0,8))}{(8557 - 5608)} = 0,108$$

$$\text{Data ke-2} = -0,8 + \frac{(7435 - 5608)(0,8 - (-0,8))}{(8557 - 5608)} = 0,191$$

$$\text{Data ke-3} = -0,8 + \frac{(7525 - 5608)(0,8 - (-0,8))}{(8557 - 5608)} = 0,240$$

$$\text{Data ke-4} = -0,8 + \frac{(7523 - 5608)(0,8 - (-0,8))}{(8557 - 5608)} = 0,238$$

Berikutnya adalah membentuk pola data *training*:

**Tabel 3. 4** Pola Data *Training*

Data ke-	X1	X2	T
1	0,108	0,191	0,240
2	0,191	0,240	0,238

## 2. Proses *Training*

Dalam melakukan peramalan, perlu dilakukannya proses *training* terlebih dahulu. Tujuan dari proses *training* untuk mendapat nilai *output weight*. Selain itu tujuan lainnya yaitu supaya mendapatkan nilai kesalahan yang rendah. Berikut merupakan tahapan dari proses *training*:

- a. Menciptakan nilai *input weight* secara acak yang sebelumnya didapatkan dari proses *training*

$$W_{1,1} = -0,50$$

$$W_{1,2} = -0,49$$

$$W_{1,3} = -0,45$$

$$W_{1,4} = -0,26$$

- b. Menghitung nilai *output* dari *hidden layer* dengan persamaan sebagai berikut:

$$H_{init} = (\sum_{i=1}^n x \times W)$$

(3.9)

dengan:

$H_{init}$  = Matriks *output hidden layer*

$x$  = Matriks *input* yang telah dinormalisasi

$w$  = Bobot *input weight*

$$H_{init} = \begin{vmatrix} 0,108 & 0,191 \\ 0,191 & 0,240 \end{vmatrix} \times \begin{vmatrix} -0,50 & -0,45 \\ -0,49 & -0,26 \end{vmatrix} \\ = \begin{vmatrix} -0,147 & -0,098 \\ -0,213 & -0,148 \end{vmatrix}$$

- c. Mengaktifkan semua nilai *output* pada *hidden layer* dengan persamaan sebagai berikut:

$$H(x) = \frac{1}{1+e^{-x}} \quad (3.10)$$

dengan:

$H(x)$  = Matriks *output* dari *hidden layer*

$x$  = Matriks *input* yang telah dinormalisasi

$$H(x) = \begin{bmatrix} 0,463 & 0,475 \\ 0,446 & 0,462 \end{bmatrix}$$

- d. Menghitung matriks *Moore-Penrose Generalized Inverse* Matriks ini didapatkan dari Langkah sebelumnya, yaitu mengalikan matriks *transpose* dari hasil aktivasi nilai *output* pada *hidden layer*. Dapat dihitung dengan cara:

$$H^+ = (H(x)^T \cdot H(x))^{-1} \cdot H(x)^T \quad (3.11)$$

dengan:

$H^+$  = Matriks *Moore-Penrose Generalized Inverse*

$H_{(x)}^T$  = Matriks yang di *transpose*

$$\begin{aligned} H^+ &= \left[ \begin{bmatrix} 0,463 & 0,446 \\ 0,475 & 0,462 \end{bmatrix}^T \begin{bmatrix} 0,463 & 0,475 \\ 0,446 & 0,462 \end{bmatrix} \right]^{-1} \begin{bmatrix} 0,463 & 0,446 \\ 0,475 & 0,462 \end{bmatrix} \\ &= \begin{bmatrix} 0,414 & 0,427 \\ 0,427 & 0,440 \end{bmatrix}^{-1} \begin{bmatrix} 0,463 & 0,446 \\ 0,475 & 0,462 \end{bmatrix} \\ &= \begin{bmatrix} 116373,31 & -112865,75 \\ -112865,75 & 109466,18 \end{bmatrix}^{-1} \begin{bmatrix} 0,463 & 0,446 \\ 0,475 & 0,462 \end{bmatrix} \\ &= \begin{bmatrix} 237,991 & -244,404 \\ -229,739 & 238,088 \end{bmatrix} \end{aligned}$$

- e. Menghitung *output weight* yaitu bobot antara *hidden layer* dengan *output layer* yaitu mengalikan matriks *Moore-Penrose Generalized Inverse* dengan matriks target, dapat dihitung dengan persamaan:

$$\beta = H^+ \cdot T \quad (3.12)$$

dengan:

$\beta$  = Matriks *output weight*

$H^+$  = Matriks *Moore-Penrose Generalized Inverse*

$T$  = Matriks target

$$\begin{aligned} \beta &= \begin{bmatrix} 237,991 & -244,404 \\ -229,739 & 238,088 \end{bmatrix} \begin{bmatrix} 0,240 \\ 0,238 \end{bmatrix} \\ &= \begin{bmatrix} -1,050 \\ 1,527 \end{bmatrix} \end{aligned}$$

- f. Menghitung peramalan yang didapatkan dari nilai *output layer* dengan cara mengalikan matriks *output weight* dengan matriks *output* dari *hidden layer*, dengan persamaan:

$$y = H(x) \cdot \beta \quad (3.13)$$

dengan:

$y$  = Matriks hasil peramalan

$H(x)$  = matriks *output* dari *hidden layer*

$\beta$  = matriks *output weight*

$$y = \begin{bmatrix} 0,463 & 0,475 \\ 0,446 & 0,462 \end{bmatrix} \times \begin{bmatrix} -1,050 \\ 1,527 \end{bmatrix} \\ = \begin{bmatrix} 0,24 \\ 0,238 \end{bmatrix}$$

### 3. Proses *Testing*

Proses *testing* dilakukan untuk mengevaluasi kemampuan model dalam meramalkan dari metode *Extreme Learning Machine* yang sebelumnya telah dilakukan dengan menggunakan proses *testing*

### 4. Denormalisasi

Proses denormalisasi terjadi ketika proses normalisasi yang mengubah nilai dari data asli yang dilakukan sebelumnya, maka dengan proses denormalisasi ini data diubah ke bentuk asli lagi (Giusti, Widodo, & Adinugroho, 2018). Berikut adalah proses perhitungan denormalisasi :

$$X = (X' (X_{max} - X_{min}) ) + X_{min} \quad (3.14)$$

dengan:

$X'$  = data hasil normalisasi

$X$  = data asli

$X_{min}$  = nilai minimum data asli

$X_{max}$  = nilai maksimum data asli

$$X = \begin{bmatrix} 6315 \\ 6309 \end{bmatrix}$$

### 3.16. Tingkat Signifikansi dan *P-value*

Tingkat signifikansi merupakan kesalahan tipe I atau tipe pertama yang ditentukan oleh peneliti yang kaitannya dengan akibat dari terjadinya kesalahan tersebut. Nilai (*p-value*) adalah probabilitas bahwa sampel yang diambil dari populasi akan diuji memberikan asumsi untuk gagal tolak hipotesis nol. Dalam hal ini apabila  $p\text{-value} < \alpha$ , maka uji hipotesis menunjukkan tolak hipotesis nol, dan sebaliknya. Apabila  $p\text{-value} > \alpha$ , maka uji hipotesis menunjukkan gagal menolak hipotesis nol. Hal ini menunjukkan, *p-value* yang semakin dekat dengan nilai nol, semakin besar kemungkinan tolak hipotesis nol. Sebaliknya, *p-value* yang semakin dekat dengan angka satu, maka semakin besar kemungkinan gagal tolak hipotesis nol (Putriana, 2014).

### 3.17. Ukuran Kesalahan Peramalan

Besar kecilnya kesalahan prediksi sangatlah penting maknanya, baik buruknya hasil peramalan suatu model akan menentukan keputusan apakah model tersebut layak digunakan atau tidak. Hasil peramalan yang baik adalah ketika diperoleh tingkat kesalahan yang kecil, jika tingkat kesalahan semakin kecil maka artinya nilai peramalan mendekati nilai aktual atau nilai aslinya. Besar kecilnya kesalahan peramalan tersebut dapat dihitung dengan menggunakan berbagai metode, salah satunya adalah dengan menggunakan nilai MAPE atau *Mean Absolute Percentage Error* (Robial, 2018).

Berikut merupakan tabel kriteria nilai MAPE:

**Tabel 3. 5** Kategori Ukuran Kesalahan

Nilai MAPE	Kategori
<10%	Kemampuan model peramalan sangat baik
$10\% \leq \text{MAPE} < 20\%$	Kemampuan model peramalan baik
$20\% \leq \text{MAPE} < 50\%$	Kemampuan model peramalan cukup
$\geq 50\%$	Kemampuan model peramalan buruk

Sumber: (Lewis, 1982)

MAPE atau presentase kesalahan rata-rata absolut ini menghitung perbedaan antara nilai aktual dan nilai peramalan. Selisih dari nilai aktual dan nilai peramalan di absolutkan, kemudian dihitung dalam bentuk presentase terhadap nilai aktualnya. Nilai MAPE dapat dicari dengan menggunakan rumus sebagai berikut:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \frac{|X_t - X'_t|}{X_t} \quad (3.15)$$

dengan:

$X_t$  = data aktual pada data ke-t

$X'_t$  = data peramalan pada data ke-t

$n$  = jumlah data

(Prianda & Widodo, 2021 )

**Contoh:**

**Diketahui:**

**Tabel 3. 6** Contoh Mencari Nilai MAPE

Tahun	Bulan	Data Aktual	Data Prediksi
2021	Jan	10.836	10.387
2021	Feb	11.681	9.451
2021	Mar	10.092	7.879
2021	Apr	14.065	7.879
2021	Mei	12.980	6.719
2021	Jun	13.056	7.223

**Ditanya:** nilai MAPE

**Jawab:**

$$\begin{aligned}
 MAPE &= \frac{100\%}{n} \sum_{t=1}^n \frac{|X_t - X'_t|}{X_t} \\
 &= \frac{100\%}{6} \times 1.821 \\
 &= \frac{182,1\%}{6} \\
 &= 30,3\%
 \end{aligned}$$



## BAB IV METODOLOGI PENELITIAN

### 4.1. Populasi Penelitian

Pada penelitian ini populasi yang digunakan adalah jumlah buruh pabrik di PT. Boyang Industrial. Sedangkan sampel yang digunakan adalah jumlah buruh pabrik di PT. Boyang Industrial pada bulan Januari 2016 sampai dengan Desember 2021.

### 4.2. Variabel penelitian

Variabel penelitian yang digunakan dalam penelitian ini hanya menggunakan dua variabel yaitu jumlah buruh pabrik di PT. Boyang Industrial dan waktu jumlah buruh pabrik merupakan banyaknya buruh yang bekerja di oleh PT. Boyang Industrial sedangkan variabel waktu yang merupakan runtun waktu dari Januari 2016 sampai Desember 2021.

**Tabel 4. 1** Tabel Definisi Operasional Variabel

No	Nama Variabel	Deskripsi	Satuan
1	Jumlah Buruh Pabrik	Jumlah buruh pabrik yang terserap di PT. Boyang Industrial	Orang
2	Waktu	Runtun waktu dari Januari 2016 sampai Desember 2021	Bulan

### 4.3. Teknik Pengambilan Data

Data yang digunakan oleh peneliti merupakan data sekunder yang diperoleh dari PT. Boyang Industrial dengan teknik *non probability sampling* karena pengambilan sampling yang tidak memberi peluang atau kesempatan yang sama pada setiap unsur (anggota populasi) untuk dipilih menjadi sampel.

### 4.4. Metode Analisis Data

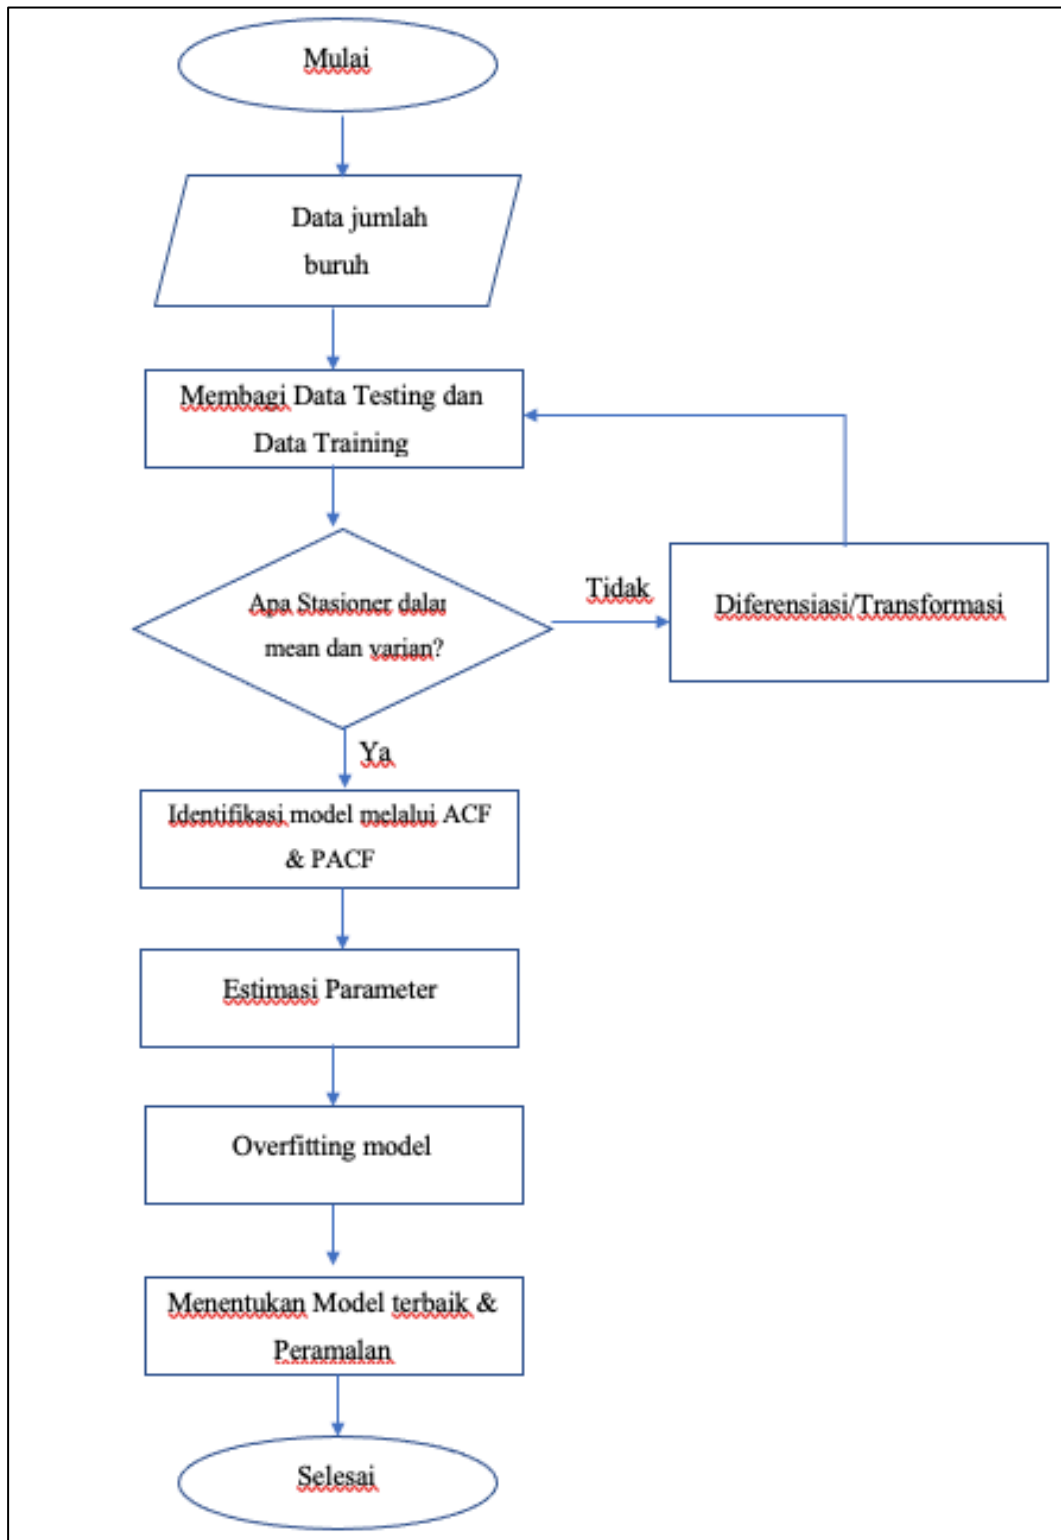
Metode analisis data dalam penelitian ini untuk memvisualisasikan jumlah buruh pabrik di PT. Boyang Industrial yaitu analisis deskriptif dengan menggunakan *software excel*. Untuk mengetahui prediksi jumlah buruh pabrik diwaktu akan datang peneliti menggunakan metode ARMA dan ELM dengan menggunakan *software R Studio*. Dengan metode ARMA dan ELM selain dapat

memprediksi jumlah buruh pabrik mendatang dapat juga mengetahui tingkat akurasi/ketepatan dalam memprediksi menggunakan nilai MAPE.

#### 4.5. Tahap Penelitian Metode ARMA

Berikut merupakan langkah-langkah dalam melakukan peramalan menggunakan metode ARMA:

1. Input data jumlah buruh di PT. Boyang Industrial pada bulan Januari 2016 sampai Desember 2021 ke dalam *software R*.
2. Mengubah data menjadi data *time series*
3. Membagi data menjadi data *training* dan data *testing*
4. Dilakukan uji stasioneritas terhadap rata-rata dan varian. Apabila tidak stasioner maka dilakukan diferensiasi dan transformasi, apabila data sudah stasioner maka dilanjutkan ke tahap berikutnya .
5. Menentukan estimasi parameter untuk pembuatan model ARMA
6. Uji diagnostik untuk melihat kelayakan model.
7. Melakukan peramalan untuk periode ke depan

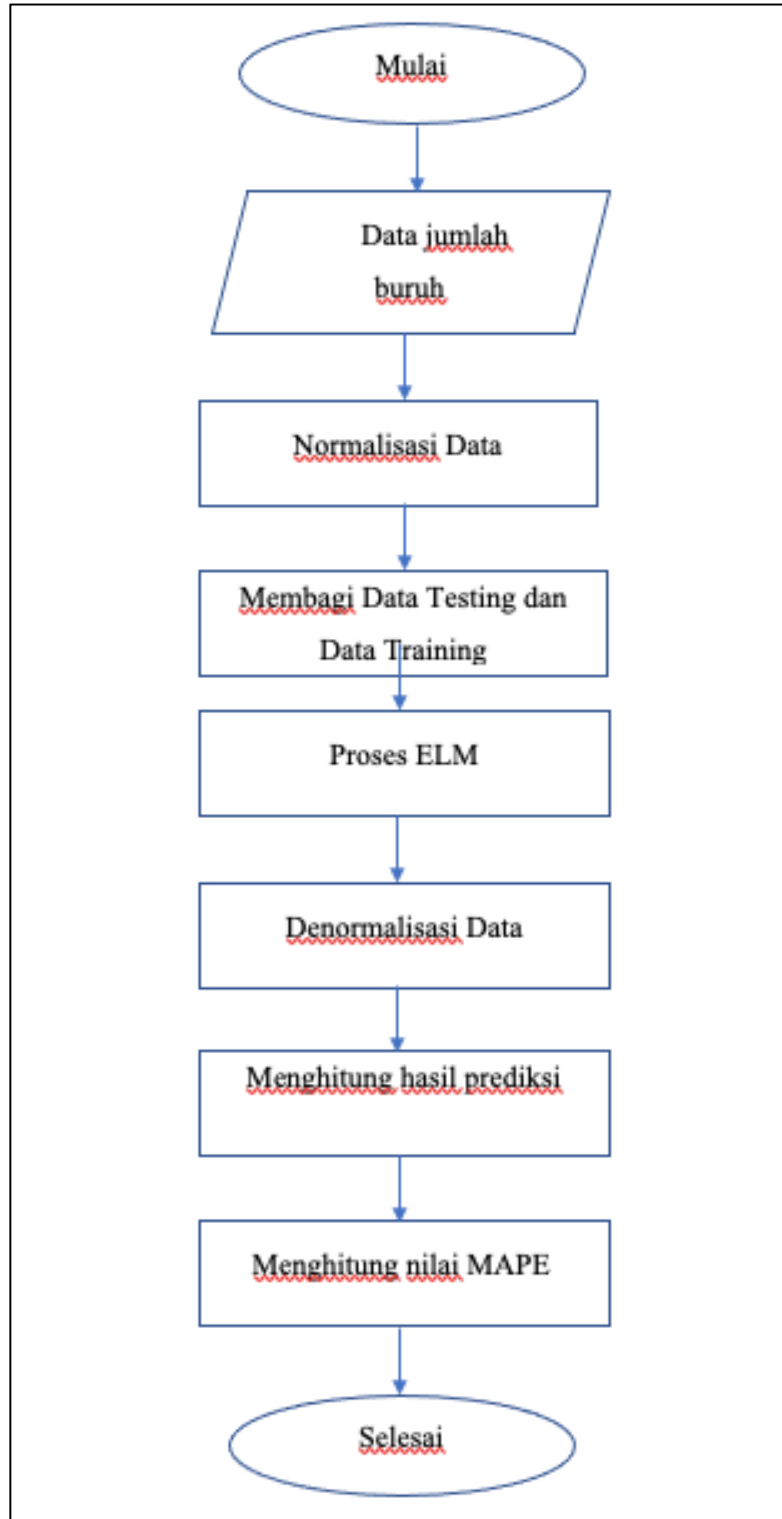


Gambar 4. 1 Diagram Alir ARMA

#### 4.6. Tahap Penelitian Metode ELM

Berikut merupakan langkah-langkah dalam melakukan peramalan menggunakan metode ELM:

1. Input data jumlah buruh di PT. Boyang Industrial pada bulan Januari 2016 sampai Desember 2021 ke dalam *software R*.
2. Normalisasi data
3. Membagi data *testing* dan data *training*
4. Mencari nilai prediksi menggunakan data *training*
5. Denormalisasi data
6. Menghitung hasil prediksi
7. Mencari nilai akurasi untuk mengukur ketepatan peramalan dengan menggunakan nilai MAPE




Gambar 4. 2 Diagram Alir ELM

**BAB V**  
**HASIL DAN PEMBAHASAN**

**5.1. Analisis Deskriptif**

Pergerakan jumlah buruh pabrik yang ada di PT. Boyang Industrial disajikan dalam **Gambar 5. 1**.



**Gambar 5. 1** Grafik Jumlah Buruh Pabrik

Berdasarkan **Gambar 5. 1** dapat diketahui jumlah buruh pabrik di PT.Boyang Industrial mengalami peningkatan banyaknya buruh dari tahun 2016 hingga 2021 dengan menggunakan trend linear metode kuadrat terkecil. Untuk memudahkan dalam perhitungan, maka digunakan tabel berikut:

**Tabel 5. 1** Tabel perhitungan konstanta persamaan linear

Tahun	Bulan	$X_t$	$Y_t$	$xt^2$	$X_tY_t$
2016	Januari	-36	7282	1296	-262152
2016	Febuari	-35	7435	1225	-260225
2016	Maret	-34	7525	1156	-255850
:	:	:	:	:	:
2021	Oktober	34	7516	1156	255544
2021	November	35	7312	1225	255920
2021	Desember	36	7045	1296	253620
jumlah		0	530399	32412	240367

dengan:

$X_t$  : nilai kode tahun

$Y_t$  : Data jumlah buruh pabrik

$$b_1 : \frac{\sum X_t Y_t - \sum X_t \sum Y_t / n}{\sum X_t^2 - \sum X_t^2 / n}$$

$$: \frac{19595192 - (2626 \times 530399) / 72}{127020 - 127020 / 10}$$

$$: \frac{235628,5}{125255,833}$$

: 1.88

$$b_0 : \frac{\sum Y_t}{n} - b_1 \frac{\sum X_t}{n}$$

$$: \frac{19595192}{72} - 1,88 \frac{2628}{72}$$

$$: 7366,6 - 36,5$$

$$: 7297,9$$

$$\widehat{Y}_t : b_0 + b_1(X_t)$$

$$\widehat{Y}_t : 7297,9 + 1,88(X_t)$$

**Tabel 5. 2** Tabel hasil perhitungan persamaan linear


Tahun	Bulan	$Y_t$	$\widehat{Y}_t$
2016	Januari	7282	7096
2016	Febuari	7435	7103
2016	Maret	7525	7111
:	:	:	:
2021	Oktober	7516	7622
2021	November	7312	7630
2021	Desember	7045	7637

**Tabel 5.2** inilah yang digunakan untuk membuat grafik *trendline* linear metode kuadrat terkecil seperti pada **Gambar 5.1**.



## 5.2. Metode *Autoregressive Moving Average* (ARMA)

### 5.2.1 Membuat Plot



**Gambar 5. 2** Grafik Buruh Pabrik Tahun 2016-2021

Berdasarkan **Gambar 5. 2** terlihat bahwa data buruh pabrik PT.Boyang Industrial berfluktuasi, mengalami peningkatan dan penurunan serta mengandung unsur *trend*.

### 5.2.2 Pembagian Data Training dan Data Testing

Sebelum melakukan permalan, data dibagi menjadi dua yaitu data *training* dan data *testing*. Data *training* digunakan untuk mendapatkan model sementara data *testing* digunakan untuk menguji ketepatan model. (Musu, Ibrahim, & Heriadi, 2021) Pembagian data *training* dan *testing* sebesar 80%:20%, dikarenakan dengan menggunakan presentase tersebut didapatkan nilai MAPE yang paling kecil dibandingkan perbandingan presentase lainnya yakni 70%:30% dan 90%:10%.

**Tabel 5. 3** Pembagian Data *Training* dan Data *Testing* ARMA

Pembagian	Presentase	Total Data
Data <i>Training</i>	80%	58
Data <i>Testing</i>	20%	14
Total	100%	72

Pada proses *training*, digunakan sebanyak 80% data dari total data keseluruhan, proses *training* dilakukan untuk mendapatkan model. Sehingga didapatkan data yang akan menjadi model sebanyak 58 data yaitu data jumlah buruh pabrik bulan Januari 2016 sampai bulan Oktober 2020.

Pada proses *testing* data digunakan sebanyak 20% dari total data atau sebanyak 14 data data jumlah buruh pabrik bulan November 2020 sampai bulan Desember 2021. Proses *testing* bertujuan untuk melihat ketepatan model dalam melakukan peramalan. Berikut merupakan hasil pembagian data *training* dan data *testing* pada data jumlah buruh pabrik:

**Tabel 5. 4** Hasil Pembagian Data *Training* Jumlah Buruh Pabrik

<b>Data training</b>					
<b>Bulan</b>	<b>Tahun</b>				
	<b>2016</b>	<b>2017</b>	<b>2018</b>	<b>2019</b>	<b>2020</b>
Januari	7282	7208	7056	6621	7556
Februari	7435	7173	7065	6894	7319
Maret	7525	7116	7066	6612	6492
April	7523	7110	7124	6666	5923
Mei	7734	7154	7056	6887	5608
Juni	7626	7034	7065	6969	5944
Juli	7719	7422	7066	7218	6977
Agustus	7730	7465	7124	7188	7983
September	7676	7543	6621	7411	8373
Oktober	7480	7369	6894	7830	8348
November	7340	7158	6612	8047	
Desember	7228	6996	6666	7939	

**Tabel 5. 5** Hasil Pembagian Data *Testing* Jumlah Buruh Pabrik

<b>Data testing</b>		
<b>Bulan</b>	<b>Tahun</b>	
	<b>2020</b>	<b>2021</b>
Januari		8527
Febuari		8557
Maret		8502
April		8388
Mei		8411
Juni		8250
Juli		8258
Agustus		8223
September		8078
Oktober		7516
November	8228	7312
Desember	7838	7045

### 5.2.3 Uji Stasioneritas Rata-Rata

Identifikasi parameter ini dilakukan uji ADF apakah data stasioner atau tidak.

1. Hipotesis

$H_0$  : Rata-rata data jumlah buruh pabrik tidak stasioner

$H_1$  : Rata-rata data jumlah buruh pabrik stasioner

2. Taraf signifikansi

$$\alpha = 0.05$$

3. Daerah Kritis

Tolak  $H_0$  jika  $|\tau| > |ADF \text{ critical values}|$

#### 4. Statistik Uji

**Tabel 5. 6** Hasil Uji Stasioneritas Rata-Rata

Pengujian	$\tau$	ADF <i>critical values</i>
Stasioneritas	-3,322	1%: -3,527
		5%: -2,903
		10%: -2,58

Sumber: R Studio

#### 5. Keputusan

Didapatkan nilai  $|\tau| = 3,322 > |\text{ADF } \textit{critical values}| = 2,903$  berarti tolak  $H_0$

#### 6. Kesimpulan

Dengan menggunakan tingkat kepercayaan 95%, data yang ada tolak  $H_0$  yang berarti rata-rata data jumlah buruh pabrik stasioner.

### 5.2.4 Uji Stasioneritas Varians

Uji stasioneritas varians ini menggunakan menggunakan metode *Box-Cox*. Apabila nilai  $\lambda \geq 1$ , maka data dikatakan stasioner terhadap variansi (Pamungkas & Wibowo, 2018).

**Tabel 5. 7** Hasil Uji Stasioneritas Varians (*R Studio*)

Pengujian	$\lambda$
<i>Box-Cox</i>	0,8404

Sumber: R Studio

Berdasarkan **Tabel 5. 5** yang memuat nilai  $\lambda$ , diperoleh nilai  $\lambda$  kurang dari 1 yang berarti bahwa data jumlah buruh pabrik PT.Boyang Industrial pada pada bulan Januari 2016 hingga Desember 2021 tidak stasioner terhadap variansi sehingga harus dilakukan transformasi agar data stasioner. Transformasi yang dilakukan yaitu transformasi *logaritma* yang dihitung menggunakan *microsoft excel*.

**Tabel 5. 8** Hasil Uji Stasioneritas Varians Setelah di Transformasi


Pengujian	$\lambda$
<i>Box-Cox</i>	1,999924

Sumber: R Studio

Hasil tranformasi *box-cox* pada **Tabel 5. 6** memuat nilai lambda dari metode *Box-Cox*, diperoleh nilai lambda 1,999924 yang berarti bahwa data jumlah buruh pabrik PT.Boyang Industrial pada bulan Januari 2016 hingga Desember 2021 telah stasioner terhadap variansi.

Berdasarkan uji ADF dan nilai lambda *Box-Cox* disimpulkan bahwa data jumlah buruh pabrik PT.Boyang Industrial pada bulan Januari 2016 hingga Desember 2021 telah stasioner terhadap rata – rata dan variansi sehingga tahap selanjutnya yaitu dilakukan identifikasi model berdasarkan plot ACF dan PACF, berikut merupakan tampilan dari plot ACF dan PACF.

### 5.2.5 Menentukan Model ARMA



**Gambar 5. 3** Plot ACF dan PACF

Berdasarkan **Gambar 5. 3** terlihat bahwa lag pada plot ACF *cut-off* pada lag ke-3 yang mengindikasikan order MA adalah 3. Sedangkan pada plot PACF *cut-off* pada lag ke-3 yang mengindikasikan order AR adalah 3. Kemudian pada tahapan sebelumnya tidak dilakukan *differensiasi* sehingga untuk *order d* adalah 0. Oleh karena itu didapatkan model ARMA (3, 0, 3).

Sumbu Y pada ACF menyatakan nilai autokorelasi, sedangkan sumbu Y pada PACF menyatakan autokorelasi parsialnya. Kemudian sumbu X pada ACF dan PACF menyatakan lag ke-1, lag ke-2, dan seterusnya. Garis biru menandakan batas interval, jika melewati batas interval itu artinya terdapat autokorelasi dan autokorelasi parsial. Panjang ataupun pendeknya batang di tiap ACF dan PACF tergantung pada nilai autokorelasi dan autokorelasi parsial di tiap lag nya.

Berikut merupakan perhitungan manual dari ACF lag ke-1 dan ke-2:

$$\rho_1 = \frac{0,08707}{0,09902} = 0,879$$

$$\rho_2 = \frac{0,06526}{0,09902} = 0,659$$

Nilai ACF lag ke-1 atau batang pertama adalah 0.879. nilai ACF lag ke-1 bernilai positif sehingga batang ke arah atas. Kemudian, Nilai ACF lag ke-2 atau batang kedua adalah 0,659. nilai ACF lag ke-2 juga bernilai positif sehingga batang ke arah atas.

Berikut merupakan perhitungan manual dari PACF lag ke-1 dan ke-2:

$$\phi_{1,1} = \rho_1$$

$$\phi_{1,1} = 0,879$$

$$\phi_{2,2} = \frac{\rho_2 - \phi_{1,1} \rho_1}{1 - \phi_{1,1} \rho_1}$$

$$\phi_{2,2} = \frac{0,659 - (0,879 \times 0,879)}{1 - (0,879 \times 0,879)}$$

$$\phi_{2,2} = \frac{-0,11364}{0,22735}$$

$$\phi_{2,2} = -0,499$$

Nilai PACF lag ke-1 atau batang pertama adalah 0,879. nilai ACF lag ke-1 bernilai positif sehingga batang ke arah atas. Kemudian, Nilai PACF lag ke-2 atau batang kedua adalah -0,499. nilai PACF lag ke-2 bernilai negatif sehingga batang muncul ke arah bawah.

Selanjutnya dilakukan pendugaan terhadap model dengan cara memilih model dengan order lebih rendah atau kombinasi dari order pada model utama. Dalam penelitian ini diperoleh 15 model sementara yaitu; ARMA(3, 0, 3) ; ARMA(3, 0, 2) ; ARMA(3, 0, 1) ; ARMA(3, 0, 0) ARMA(2, 0, 3) ; ARMA(2, 0, 2) ; ARMA(2, 0, 1) ; ARMA(2, 0, 0) ; ARMA(1, 0, 3) ; ARMA(1, 0, 2) ; ARMA(1, 0, 1) ; ARMA(1, 0, 0) ; ARMA(0, 0, 3) ; ARMA(0, 0, 2) ; ARMA(0, 0, 1)

### 5.2.6 Estimasi Parameter

1. Hipotesis

$H_0$  : Koefisien-koefisien tidak signifikan terhadap model

$H_1$  : Koefisien-koefisien signifikan terhadap model

2. Taraf Signifikansi

$\alpha = 0.05$

3. Daerah Kritis

Tolak  $H_0$  jika  $p\text{-value} < \alpha$  atau tolak  $H_0$  jika  $t_{hitung} > t_{tabel}$

4. Statistik Uji dan Keputusan

**Tabel 5. 9**  $t_{hitung}$  dari masing-masing parameter

ARMA	t-tabel	AR1	AR2	AR3	MA1	MA2	MA3	KEPUTUSAN
(3, 0, 3)		2,303	<b>0,728</b>	-2,496	<b>1,361</b>	<b>0,378</b>	<b>0,242</b>	<b>Gagal Tolak <math>H_0</math></b>
(3, 0, 2)		2,992	<b>0,654</b>	-2,467	<b>1,418</b>	<b>0,289</b>		<b>Gagal Tolak <math>H_0</math></b>
(3, 0, 1)		3,585	<b>1,156</b>	-4,065	<b>1,723</b>			<b>Gagal Tolak <math>H_0</math></b>
(3, 0, 0)		9,425	<b>-0,986</b>					<b>Gagal Tolak <math>H_0</math></b>
(2, 0, 3)		9,734	-6,607		<b>-1,308</b>	<b>1,669</b>	<b>-0,719</b>	<b>Gagal tolak <math>H_0</math></b>
(2, 0, 2)		9,109	-5,658		<b>-0,992</b>	2,025		<b>Gagal Tolak <math>H_0</math></b>
(2, 0, 1)	1,993943	15,308	-9,002		-2,184			Tolak $H_0$
(2, 0, 0)		13,833	-6,392					Tolak $H_0$
(1, 0, 3)		2,926			4,531	4,700	2,264	Tolak $H_0$
(1, 0, 2)		5,735			3,578	4,290		Tolak $H_0$
(1, 0, 1)		8,404			4,194			Tolak $H_0$
(1, 0, 0)		11,728						Tolak $H_0$
(0, 0, 3)					10,318	5,828	<b>1,227</b>	<b>Gagal Tolak <math>H_0</math></b>
(0, 0, 2)					17,707	7,898		Tolak $H_0$
(0, 0, 1)					11,161			Tolak $H_0$


Sumber: R Studio

5. Kesimpulan

Dengan tingkat kepercayaan 95% maka dapat disimpulkan bahwa, ARMA(2, 0, 1), ARMA(2, 0, 0), ARMA(1, 0, 3), ARMA(1, 0, 2), ARMA(1, 0, 1), ARMA(1, 0, 0), ARMA(0, 0, 2), ARMA(0, 0, 1) tolak

$H_0$  karena nilai  $|t_{hitung}| > t_{0,025;72-1}$  yang berarti bahwa model tersebut mempunyai koefisien yang signifikan terhadap model.

### 5.2.7 Uji Diagnostik



**Gambar 5. 4** Plot Uji Diagnostik ARMA(2, 0, 1)

Uji white noise suatu model dikatakan baik jika menunjukkan tidak ada autokorelasi, yang memiliki arti residual tidak berpola tertentu (Pamungkas & Wibowo, 2018). Dilihat pada *Ljung-Box* atau *box* ke-3 pada gambar, dengan tingkat kepercayaan 95%,  $H_0$  : residual tidak mengandung korelasi,  $H_1$  : residual mengandung korelasi, dan daerah kritis tolak  $H_0$  jika  $p\text{-value} < \alpha$ , maka pada ARMA(2, 0, 1) menghasilkan keputusan gagal tolak  $H_0$  yang artinya residual tidak mengandung korelasi karena tidak ada dot yang berada di bawah batas interval 0.05. Sehingga dapat dikatakan bahwa residual bersifat *white noise*

Dari ke-8 model ARMA yang signifikan, hanya terdapat 3 model yang lolos uji diagnostik, yakni ARMA(2, 0, 1), ARMA(1, 0, 3), ARMA(1, 0, 0) saja karena nilai  $p\text{-value} > 0.05$ , sedangkan sisanya memiliki nilai  $p\text{-value} < 0.05$  sehingga tolak  $H_0$  yang artinya residual mengandung korelasi.

### 5.2.8 Pemilihan Metode Terbaik

Dari 8 model yang telah signifikan dilihat nilai nilai AIC dengan menggunakan R Studio. Dari ke-3 model yang sudah lolos uji diagnostik, diperoleh nilai AIC terkecil yaitu model ARMA(2, 0, 1) sebesar -323,37, maka dapat dikatakan model ARMA(2, 0, 1) adalah model terbaik yang akan digunakan untuk melakukan peramalan.

**Tabel 5. 10** *P-value* dari masing-masing parameter

ARMA	AIC
(2, 0, 1)	-323,37
(1, 0, 3)	-318,88



$$(1, 0, 0) \quad -293,43$$


Sumber: R Studio

### 5.2.9 Peramalan dengan Metode ARMA

**Tabel 5. 11** Hasil Peramalan Metode ARMA(2, 0, 1)

Periode	Data Prediksi
Januari 2022	7108
Febuari 2022	7020
Maret 2022	6985
April 2022	7002
Mei 2022	7057
Juni 2022	7129
Juli 2022	7196
Agustus 2022	7241
September 2022	7257

Berikut merupakan plot prediksi menggunakan metode ARMA:



**Gambar 5. 5** Grafik Hasil Peramalan ARMA(2, 0, 1)

Pada **Gambar 5.6** menunjukkan hasil peramalan dengan metode ARMA(2, 0, 1) terdapat sumbu x yang adalah waktu dari data buruh pabrik PT.Boyang Industrial, sumbu y adalah jumlah dari data buruh pabrik PT.Boyang Industrial Garis yang berwarna oranye mengartikan data peramalan sedangkan, garis berwarna biru yang merupakan data aktual.

### 5.2.10 Akurasi Peramalan

Berikut adalah nilai MAPE dari pengujian model:

**Tabel 5. 12** Nilai MAPE ARMA

Model	Nilai MAPE	Tingkat Akurasi
ARMA(2, 0, 1)	0,2454%	99,7545%

Sumber: R Studio

Berdasarkan **Tabel 5. 10** nilai MAPE pada model ARMA(2, 0, 1) sebesar 0.2454% yang berarti bahwa model sangat baik untuk dilakukan peramalan karena mempunyai nilai MAPE <10%.

## 5.3. Metode *Extreme Learning Machine*

### 5.3.1 Normalisasi Data

Dalam analisis prediksi menggunakan metode ELM tahap pertama yang dilakukan yaitu melakukan normalisasi data. Tujuan dari normalisasi data yaitu mengubah *range* data menjadi lebih kecil. Pada penelitian ini *range* yang digunakan yaitu -0,8 hingga 0,8. Normalisasi data dapat dilakukan menggunakan Persamaan yaitu metode *Min-Max Normalization*.

Berikut merupakan tabel hasil normalisasi data:

**Tabel 5. 13** Hasil Normalisasi

Tahun	Bulan	Buruh Pabrik	Hasil Normalisasi
2016	Januari	7282	0,108240081
2016	Februari	7435	0,19125127
2016	Maret	7525	0,24008138
2016	April	7523	0,23899627
2016	Mei	7734	0,35347575
2016	Juni	7626	0,29487962
2016	Juli	7719	0,3453374
2016	Agustus	7730	0,35130553
2016	September	7676	0,32200746
2016	Oktober	7480	0,21566633
2016	November	7340	0,13970838
2016	Desember	7228	0,07894201
:	:	:	:
2021	Oktober	7516	0,235198372
2021	November	7312	0,124516785

### 5.3.2 Pembagian Data *Training* dan Data *Testing*

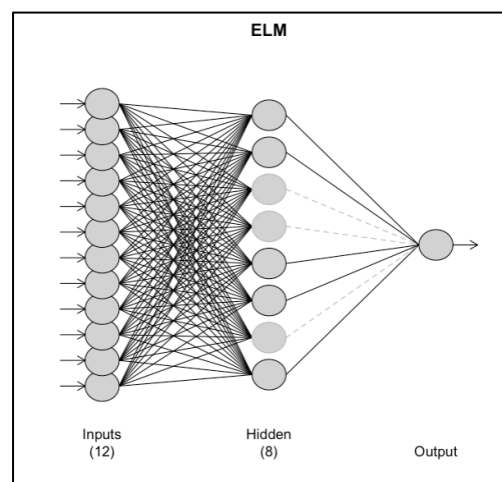
Sebelum dilakukannya proses peramalan dengan metode ELM, data dibagi menjadi dua bagian yaitu data *training* dan data *testing*. Dalam proses *training* ini digunakan untuk menghitung bobot akhir pada proses pengujian ELM. Sedangkan untuk data *testing*, dalam proses pengujian digunakan untuk menentukan tingkat akurasi hasil peramalan. Pada proses *training*, digunakan sebanyak 80% data dari total data keseluruhan, pada proses *testing* data digunakan sebanyak 20% dari total data

**Tabel 5. 14** Pembagian Data *Training* dan Data *Testing* ELM

Pembagian	Presentase	Total Data
Data <i>Training</i>	80%	58
Data <i>Testing</i>	20%	14
Total	100%	72

### 5.3.3 Arsitektur Jaringan

Arsitektur jaringan merupakan sebuah susunan dari sebuah jaringan yang isinya terdiri dari jumlah input, jumlah hidden layer dan jumlah output layer. Berikut merupakan arsitektur jaringan dari metode ELM:



**Gambar 5. 6** Arsitektur Jaringan

Pada arsitektur jaringan ELM terdapat *input layer* sebanyak 12 yang artinya terdapat 12 *input layer* yang diasumsikan mewakili jumlah bulan pada data *input*. Kemudian terdapat 8 *hidden layer* Setiap *node input* memiliki 8 bobot yang

menyebar ke masing-masing *node* pada *hidden layer*. Diketahui bahwa pada *node input X* terdapat 8 bobot, yaitu  $W_{1.1}$ ,  $W_{1.2}$ ,  $W_{1.3}$ , sampai  $W_{1.8}$ , begitu seterusnya pada *node-node input* lainnya. Lalu selanjutnya nilai *hidden layer* terbentuk sebanyak 8 *neuron* dan *output* sebanyak 1 *node*.

Pada penelitian ini peneliti akan membandingkan jumlah menggunakan *hidden layer* menggunakan *hidden layer* 2 hingga 10 neuron, bertujuan untuk mengetahui jumlah neuron yang terbaik berdasarkan nilai MAPE. Didapatkan jumlah *hidden layer* dengan nilai MAPE terkecil yaitu sejumlah 8 *hidden layer*.

**Tabel 5. 15** Uji Coba *Hidden Layer*

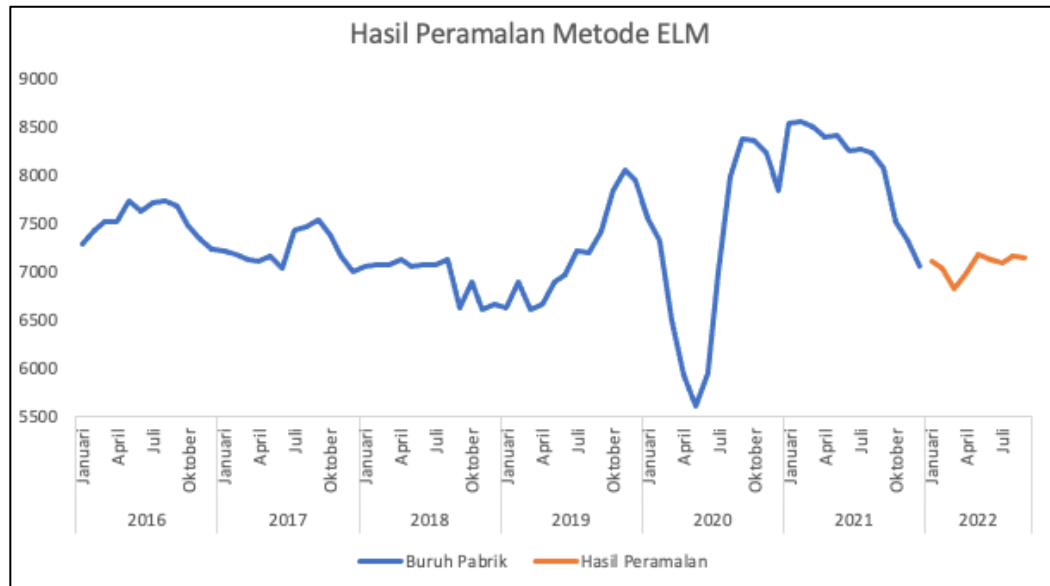
Hidden Layer	Nilai MAPE
2	12,101082
3	11,501067
4	12,207509
5	11,178325
6	11,606061
7	11,441257
<b>8</b>	<b>10,73159</b>
9	11,645607
10	11,019055

#### 5.3.4 Peramalan dengan Metode *Extreme Learning Machine*

**Tabel 5. 16** Hasil Peramalan Metode ELM

Periode	Data Prediksi
Januari 2022	7112
Febuari 2022	7040
Maret 2022	6828
April 2022	6989
Mei 2022	7181
Juni 2022	7132
Juli 2022	7082
Agustus 2022	7164
September 2022	7135

Berikut merupakan plot hasil dari prediksi:



**Gambar 5. 7** Grafik Peramalan ELM

Pada **Gambar 5.9** menunjukkan hasil peramalan dengan metode ELM. Terdapat sumbu x yang adalah waktu dari data buruh pabrik PT.Boyang Industrial, sumbu y adalah jumlah dari data buruh pabrik PT.Boyang Industrial. Garis yang berwarna oranye mengartikan data peramalan sedangkan, garis berwarna biru yang merupakan data aktual.

### 5.3.5 Akurasi Peramalan

Nilai akurasi yang digunakan dalam melakukan prediksi yaitu MAPE. Nilai MAPE dapat menentukan apakah nilai peramalan tersebut baik atau buruk. Tabel tersebut menunjukkan nilai MAPE untuk metode *Extreme Learning Machine*.

**Tabel 5. 17** Nilai MAPE ELM

Nilai MAPE	Tingkat Akurasi
10,7315%	89,2685%

Sumber: R Studio

Dapat dilihat pada tabel nilai MAPE yang didapatkan sebesar 10,7315%. Dapat dikatakan bahwa metode ELM memiliki kemampuan baik dalam memprediksi jumlah penyerapan tenaga kerja buruh pabrik di PT. Boyang Industrial.

#### 5.4. Hasil Prediksi Kedua Metode

Langkah yang terakhir yakni membandingkan nilai MAPE kedua metode. Metode dengan nilai MAPE terkecil menggambarkan bahwa metode tersebut adalah metode yang paling tepat dalam meramalkan kemampuan PT.Boyang Industrial dalam menyerap tenaga kerja buruh pabrik di masa yang akan datang.

**Tabel 5. 18** Perbandingan Metode Terbaik

Metode	Nilai MAPE
ARMA	0,2454%
ELM	10,7315%

Berdasarkan tabel di atas merupakan tabel perbandingan yang digunakan untuk menentukan ketepatan model terbaik. Didapatkan nilai MAPE untuk metode ARMA sebesar 0,2454, sedangkan nilai MAPE dari metode ELM sebesar 10,7315. Sehingga model terbaik untuk meramalakan jumlah buruh pabrik yang mampu terserap di PT. Boyang di periode selanjutnya adalah metode ARMA, karena mempunyai nilai MAPE terkecil.

## **BAB VI**

### **PENUTUP**

#### **6.1. Kesimpulan**

Berdasarkan dari rumusan masalah dan hasil penelitian yang dilakukan, maka dapat disimpulkan bahwa:

1. Jumlah buruh pabrik di PT. Boyang Industrial bergerak secara fluktuatif namun terjadi *trend* naik. Terjadi penurunan secara signifikan pada bulan Mei 2020. Hal ini terjadi dikarenakan mulai bulan Maret-April 2020 pandemi Covid-19 pertama kali muncul di Indonesia. Jumlah buruh pabrik di PT. Boyang Industrial paling rendah selama lima tahun terjadi di bulan Mei 2020 ini merupakan dampak parah dari pandemi Covid-19.
2. Perbandingan Hasil Peramalan dengan metode ARMA dan ELM berdasarkan nilai *Mean Absolute Presentase Error* (MAPE), metode yang paling akurat adalah metode ARMA(2,0,1) dengan nilai *error* terendah dengan tingkat kesalahan peramalan sebesar 0,2454% dan tingkat akurasi peramalan sebesar 99,7545% sehingga metode ARMA lebih tepat digunakan dalam peramalan ini.

#### **6.2. Saran**

Berdasarkan kesimpulan yang didapatkan saran:

1. Metode ARMA dapat digunakan untuk meramalkan jumlah buruh yang bekerja di PT. Boyang Industrial dengan tepat.
2. PT. Boyang Industrial dapat menggunakan peramalan berikut ini untuk menyusun rencana atau strategi dalam produksi.
3. Bagi penelitian selanjutnya dengan objek yang sama, dapat menggunakan metode yang lain untuk membandingkan hasil prediksi.

## DAFTAR PUSTAKA

- Aditya, D., Maesyaroh, W. U., Tanjung, I. R., & Remayasari, M. (2021). Kondisi Tingkat Pengangguran di Indonesia pada Masa Pandemi Covid-19 : Studi Kasus dengan Pendekatan Metode Arima. *Jurnal Ilmiah MEA (Manajemen, Ekonomi, dan Akuntansi) Vol. 5 No. 2*, 1665-1678.
- Adrian, S. Y., Rismawan, T., & Midyanti, D. (2019). PENERAPAN METODE EXTREME LEARNING MACHINE UNTUK PERAMALAN JUMLAH KEPADATAN PENDUDUK DI KALIMANTAN BARAT. *Coding: Jurnal Komputer dan Aplikasi*, 34-43.
- Agasta, E., Cholissodin, I., & Ratnawati, D. E. (2018). Prediksi Jumlah Produksi Kelapa Sawit Dengan Menggunakan Metode Extreme Learning Machine (ELM) (Studi kasus: PT. Sandabi Indah Lestari Kota Bengkulu). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer e-ISSN: 2548-964X Vol. 2, No. 11*, 5751-5759.
- Agustina, D. (2018). Strategi Penyerapan Tenaga Kerja Laki-Laki pada Industri Rambut Palsu di Kabupaten Purbalingga. *Economics Developmanet Analysis Journal*, 276-285.
- Ardhaninggar, A. A., & Rahmadewi. (2018). Penatalaksanaan Alopecia Areata. *Berkala Ilmu Kesehatan Kulit dan Kelamin Vol. 30 No. 1*, 34-39.
- Astutik, S. P., Sukestiyarno, & Hendikawati, P. (2018). Peramalan Inflasi di Demak Menggunakan Metode ARIMA Berbantuan Software R dan MINITAB. *Prosiding Seminar Nasional Matematika* (hal. 745-754). Semarang: Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang.
- Atmaja, M. A., Kencana, I. E., & Gandhiadi, G. K. (2015). ANALISIS KOINTEGRASI JUMLAH WISATAWAN, INFLASI, DAN NILAI TUKAR TERHADAP PRODUK DOMESTIK REGIONAL BRUTO (PDRB) POVINSI BALI. *E-Jurnal Matematika*, 83-89.
- Badieah, Gernowo, R., & Surarso, B. (2016). Metode Jaringan Syaraf Tiruan Untuk Prediksi Performa Mahasiswa Pada Pembelajaran Berbasis Problem Based Learning (PBL). *Jurnal Sistem Informasi Bisnis*, 46-58.



- Bai, Z. (2015). *Extreme Learning Machine with Sparse Connections*. Singapore: Nanyang Technological University, Singapore.
- Chamidah, N., Wiharto, & Salaman, U. (2012). Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagasi Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi. *JURNAL ITSMART*, 28-33.
- Darwin, E. (2018). Alopecia Areata: Review of Epidemiology, Clinical Features, Pathogenesis, and New Treatment Option. *International Journal of Trichology*, 10(2) : 51-60.
- Desvina, A. P., & Yuliasari, F. (2020). Peramalan Nilai Indeks Harga Saham Syariah Menggunakan Metode Box-Jenkins. *Jurnal Sains Matematika dan Statistika*, 50-57.
- Desvina, A. P., Khusnihita, R., & Rahmadeni. (2020). Aplikasi Metode Box-Jenkins untuk Memprediksi Jumlah Kasus Penyakit ISPA di RSUD Arifin Achmad Provinsi Riau. *Seminar Nasional Teknologi Informasi, Komunikasi dan Industri (SNTIKI)* (hal. 632-638). Pekanbaru: Fakultas Sains dan Teknologi, UIN Sultan Syarif Kasim Riau.
- Firman, Arifin, Z., & Hatta, H. R. (2019). Sistem Peramalan Kesempatan Kerja Terhadap Pencari Kerja Terdaftar Dengan Metode Arima Pada Kota Samarinda. *Prosiding Seminar Nasional Ilmu Komputer dan Teknologi Informasi* (hal. 68-75). Samarinda: Universitas Mulawarman.
- Giusti, A., Widodo, A. W., & Adinugroho, S. (2018). Prediksi Penjualan Mi Menggunakan Metode Extreme Learning Machine (ELM) di Kober Mie Setan Cabang Soekarno Hatta. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer Vol. 2, No. 8*, 2972-2978.
- Hendriyanto, H., & Sutanto, H. T. (2018). Penerapan Metode ARMA dalam Peramalan Jumlah Pelanggan Internet di Surabaya . *Jurnal Ilmiah Matematik*, 9-12.
- Hutasuhut, A. H., Anggraeni, W., & Tyasnurita, R. (2014). Pembuatan Aplikasi Pendukung Keputusan Untuk Peramalan Persediaan Bahan Baku Produksi Plastik Blowing dan Inject Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average) Di CV. Asia. *JURNAL TEKNIK POMITS Vol. 3, No. 2*, 169-174.

- Jamila, A. U., Siregar, B. M., & Yunis, R. (2021). Analisis Runtun Waktu Untuk Memprediksi Jumlah Mahasiswa Baru Dengan Model Arima. *Paradigma*, 85-92.
- Juarna, A., & Sulaiman, A. (2021). Peramalan Tingkat Pengangguran di Indonesia Menggunakan Metode Time Series dengan Model ARIMA dan Holt-Winters. *Jurnal Ilmiah Informatika Komputer Volume 26 No.1*, 14-28.
- Kertayuga, D., Santoso, E., & Hidayat, N. (2021). Prediksi Nilai Ekspor Impor Migas Dan Non-Migas Indonesia Menggunakan Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer Vol. 5, No. 6*, 2792-2800.
- Lailiyah, W. H. (2018). PENERAPAN METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) PADA PERAMALAN NILAI EKSPOR DI INDONESIA. *Jurnal Ilmiah Matematika Volume 6 No. 3*, 45-52.
- Lewis, C. D. (1982). Industrial and Business Forecasting Methods. *Journal of Forecasting*, 194-196.
- Libianto, M. S., Tibyani, & Sari, Y. A. (2019). Prediksi Jumlah Kunjungan Wisatawan Mancanegara Pada Negara Singapura Menggunakan Algoritme Extreme Learning Machine . *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer Vol. 3, No. 10*, 10324-10330.
- Melyani, C. A., Nurtsabita, A., Shafa, G. Z., & Widodo, E. (2021). Peramalan Inflasi di Indonesia menggunakan Metode Autoregressive Moving Average. *JAMES*, 67-74.
- Musu, W., Ibrahim, A., & Heriadi. (2021). Pengaruh Komposisi Data Training dan Testing terhadap Akurasi Algoritma C4.5. *PROSIDING SEMINAR ILMIAH SISTEM INFORMASI DAN TEKNOLOGI INFORMASI* (hal. 186-195). Makassar: Pusat Penelitian dan Pengabdian Pada Masyarakat (P4M) Universitas Dipa Makassar.
- Nasution, D. A., Erlina, Muda, I. (2020). Pandemi Covid-19 Terhadap Perekonomian Indonesia. *Jurnal Benefita 5(2)*, 212-224.
- Nasution, D. A., Khotimah, H. K., & Chamidah, N. (2019). PERBANDINGAN NORMALISASI DATA UNTUK KLASIFIKASI WINE

- MENGGUNAKAN ALGORITMA K-NN. *CESS (Journal of Computer Engineering System and Science)*, 78-82.
- Nasution, L. M. (2017). STATISTIK DESKRIPTIF . *Jurnal Hikmah, Volume 14, No. 1*, 49-55.
- Nurlifa, A., & Kusumadewi, D. (2017). Sistem Peramalan Jumlah Penjualan Menggunakan Metode Moving Average Pada Rumah Jilbab Zaky. *JURNAL INOVTEK POLBENG - SERI INFORMATIKA, VOL. 2, NO. 1*, 18-25.
- Pawestri, V., Setiawan, A., & Lilik, L. (2019). Pemodelan Data Penjualan Mobil Menggunakan Model Autoregressive Moving Average Berdasarkan Metode Bayesien. *Jurnal Sains dan Edukasi Sains*, 26-35.
- Prakoso, B. H. (2019). IMPLEMENTASI SUPPORT VECTOR REGRESSION PADA PREDIKSI INFLASI INDEKS HARGA KONSUMEN . *Jurnal Matrik Vol.19 No.1*, 155 - 162.
- Prianda, B. G., & Widodo, E. (2021 ). PERBANDINGAN METODE SEASONAL ARIMA DAN EXTREME LEARNING MACHINE PADA PERAMALAN JUMLAH WISATAWAN MANCANEGARA KE BALI. *BAREKENG: Jurnal Ilmu Matematika dan Terapan Vol. 15 No. 4*, 639-650.
- Primandari, A. H., & Kartikasari, M. D. (2020). *Analisis Runtun Waktu dengan R*. Yogyakarta: Univesitas Islam Indonesia.
- Putri, R. K., & dkk. (2021). Efek Pandemi Covid 19: Dampak Lonjakan Angka PHK Terhadap Penurunan Perekonomian di Indonesia. *Jurnal Bismak Volume 1, No 2.*, 71-76.
- Putriana,F. (2014). Aplikasi Metode Improved Chaid (Chi-squared Automatic Interaction Detection) pada Segmentasi Mahasiswa (Studi Kasus : Analisis Waktu Penyelesaian Skripsi Alumni di Prodi Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam). (Tugas Akhir, Universitas Islam Indonesia) Diakses dari <https://dspace.uui.ac.id/handle/123456789/7509>.
- Rasyidi, M. A. (2017). Prediksi Harga Bahan Pokok Nasional Jangka Pendek Menggunakan ARIMA. *Journal of Information Systems Engineering and Business Intelligence Vol. 3, No. 2*, 107-112.
- Robial, S. M. (2018). PERBANDINGAN MODEL STATISTIK PADA ANALISIS METODE PERAMALAN TIME SERIES (STUDI KASUS: PT.

- TELEKOMUNIKASI INDONESIA, TBK KANDATEL SUKABUMI).  
*Jurnal Ilmiah SANTIKA Volume 8 No. 2*, 1-17.
- Salwa, N., Tatsara, N., Amalia, R., & Zohra, A. F. (2018). Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average). *Journal of Data Analysis Vol.1, No.1*, 21-31.
- Saputri, E. A., & Ekojono. (2018). Prediksi Volume Impor Beras Nasional Menggunakan Jaringan Saraf Tiruan Metode ELM (Extreme Learning Machine). *SENTIA Vol. 10 No. 1*.
- Sari, E. N., & Mahatma, T. (2021). Peramalan Jumlah Penduduk Kabupaten Semarang dengan Metode Box-Jenkins. *Jurnal Statistika dan Aplikasinya*, 71-79.
- Saumi, F., & Amalia, R. (2020). Penerapan Model Arima untuk Peramalan Jumlah Klaim Program Jaminan Hari Tua pada BPJS Ketenagakerjaan Kota Langsa. *Barekeng: Jurnal Ilmu Matematika dan Terapan Vol. 14 Issues 4*, 491-500.
- Sholikhah, A. (2016). STATISTIK DESKRIPTIF DALAM PENELITIAN KUALITATIF. *KOMUNIKA, Vol. 10, No. 2*, 342-362.
- Sutedi, A. (2014). *Hukum Ekspor Impor*. Jakarta: Raih Asa Sukses (Penebar Swadaya Grup).
- Tauryawati, M. L., & Irawan, M. I. (2014). Perbandingan Metode Fuzzy Time Series Cheng dan Metode Box-Jenkins untuk Memprediksi IHSG. *JURNAL SAINS DAN SENI POMITS Vol. 3, No. 2*, 2337-3539.
- Vulandari, R. T., & Parwitasari, T. (2018). PERBANDINGAN MODEL AR(1), ARMA (1,1), DAN ARIMA (1,1,1) PADA PREDIKSI TINGGI MUKA AIR SUNGAI BENGAWAN SOLO PADA POS PEMANTAUAN JURUG. *MUST: Journal of Mathematics Education, Science and Technology*, 46-56.
- Wardah, S., & Iskandar. (2016). Analisis Peramalan Penjualan Produk Keripik Pisang Kemasan Bungkus (Studi Kasus : Home Industry Arwana Food Tembilahan). *Jurnal Teknik Industri, Vol. XI, No. 3*, 135-142.

- Warmansyah, J., & Hilpuah, D. (2019). Penerapan Metode Fuzzy Sugeno untuk Prediksi Persediaan Bahan Baku. *Jurnal Ilmiah Teknologi Informasi & Sains*, 12-20.
- Wellyanti, B. (2019). Peramalan Produk Domestik Regional Bruto (PDRB) Provinsi Bali Triwulanan (Q-To-Q) Tahun Dasar 2010 Dengan Model Arima. *Jurnal Ekonomi Kuantitatif Terapan*, 63-72.
- Wuryandari, M. D., & Afrianto, I. (2012). PERBANDINGAN METODE JARINGAN SYARAF TIRUAN BACKPROPAGATION DAN LEARNING VECTOR QUANTIZATION PADA PENGENALAN WAJAH. *Jurnal Komputer dan Informatika (KOMPUTA) Edisi. 1 Volume. 1*, 45-51.

## LAMPIRAN

### Lampiran 1 Data Jumlah Buruh Pabrik PT. Boyang Industrial

Tahun	Bulan	Buruh Pabrik
2016	Januari	7282
	Febuari	7435
	Maret	7525
	April	7523
	Mei	7734
	Juni	7626
	Juli	7719
	Agustus	7730
	September	7676
	Oktober	7480
	November	7340
	Desember	7228
2017	Januari	7208
	Febuari	7173
	Maret	7116
	April	7110
	Mei	7154
	Juni	7034
	Juli	7422
	Agustus	7465
	September	7543
	Oktober	7369
	November	7158
	Desember	6996
2018	Januari	7056
	Febuari	7065
	Maret	7066
	April	7124
	Mei	7056
	Juni	7065
	Juli	7066
	Agustus	7124
	September	6621
	Oktober	6894
	November	6612

	Desember	6666
	Januari	6621
	Febuari	6894
	Maret	6612
	April	6666
	Mei	6887
2019	Juni	6969
	Juli	7218
	Agustus	7188
	September	7411
	Oktober	7830
	November	8047
	Desember	7939
	Januari	7556
	Febuari	7319
	Maret	6492
	April	5923
	Mei	5608
2020	Juni	5944
	Juli	6977
	Agustus	7983
	September	8373
	Oktober	8348
	November	8228
	Desember	7838
	Januari	8527
	Febuari	8557
	Maret	8502
	April	8388
	Mei	8411
2021	Juni	8250
	Juli	8258
	Agustus	8223
	September	8078
	Oktober	7516
	November	7312
	Desember	7045

## Lampiran 2 *Script Program R Metode (ARIMA)*

```
library(tseries)
library(forecast)
library(faraway)
library(MASS)
library(EnvStats)

data <- read.csv(file.choose(),header=TRUE, sep=";")
data
data.ts = ts(data$Transformasi, start = c(2016,1),
             frequency = 12)
data.ts

plot(data.ts, main = "Buruh Pabrik PT.Boyang Industrial")
View(data)

##pembagian training dan testing
train=ts(data.ts[1:58],start = c(2016,1),frequency = 12)
train
testing=ts(data.ts[59:72],start = c(2020,11),frequency = 12)
testing

#Uji ADF untuk mengecek stasioner mean dan varians
adf.test(train)
BoxCox.lambda(data$Transformasi)

##membuat model utama
par(mfrow = c(1,2))
Acf(train, lag.max = 24)
Pacf(train, lag.max = 24)

#Model (p,d,q)
#p adalah batas keluar PACF
#q adalah batas keluar ACD
#d adalah jumlah diferensi
#ACF untuk melambangkan model MA
#PACF untuk model AR
#karena pada grafik pacf yang keluar garis titik" hanya satu
sehingga AR nya satu

modell1 = Arima(train, order = c(3,0,3))
modell1
summary(modell1)

modell2 = Arima(train, order = c(3,0,2))
modell2
summary(modell2)

modell3 = Arima(train, order = c(3,0,1))
modell3
summary(modell3)

modell4 = Arima(train, order = c(3,0,0))
modell4
summary(modell4)
```



```

model5 = Arima(train, order = c(2,0,3))
model5
summary(model5)

model6 = Arima(train, order = c(2,0,2))
model6
summary(model6)

model7 = Arima(train, order = c(2,0,1))
model7
summary(model7)

model8 = Arima(train, order = c(2,0,0))
model8
summary(model8)

model9 = Arima(train, order = c(1,0,3))
model9
summary(model9)

model10 = Arima(train, order = c(1,0,2))
model10
summary(model10)

model11 = Arima(train, order = c(1,0,1))
model11
summary(model11)

model12 = Arima(train, order = c(1,0,0))
model12
summary(model12)

model13 = Arima(train, order = c(0,0,3))
model13
summary(model13)

model14 = Arima(train, order = c(0,0,2))
model14
summary(model14)

model15 = Arima(train, order = c(0,0,1))
model15
summary(model15)

#sig. dari koefisien model
printstatarima <- function (x, digits = 4, se=TRUE, ...) {
  if (length(x$coef) > 0) {
    cat("\nCoefficients:\n")
    coef <- round(x$coef, digits = digits)
    if (se && nrow(x$var.coef)) {
      ses <- rep(0, length(coef))
      ses[x$mask] <- round(sqrt(diag(x$var.coef)), digits =
digits)
      coef <- matrix(coef, 1, dimnames = list(NULL, names(coef)))
      coef <- rbind(coef, s.e. = ses)
      statt <- coef[1,]/ses
      pval <- 2*pt(abs(statt), df=length(x$residuals)-1,
lower.tail = FALSE)

```

```

        coef <- rbind(coef,
t=round(statt,digits=digits),sign.=round(pval,digits=digits))
        coef <- t(coef)
    }
    print.default(coef, print.gap = 2)
}
}

printstatarima(model1)
printstatarima(model2)
printstatarima(model3)
printstatarima(model4)
printstatarima(model5)
printstatarima(model6)
printstatarima(model7)
printstatarima(model8)
printstatarima(model9)
printstatarima(model10)
printstatarima(model11)
printstatarima(model12)
printstatarima(model13)
printstatarima(model14)
printstatarima(model15)

tsdiag(model1)
tsdiag(model2)
tsdiag(model3)
tsdiag(model4)
tsdiag(model5)
tsdiag(model6)
tsdiag(model7)
tsdiag(model8)
tsdiag(model9)
tsdiag(model10)
tsdiag(model11)
tsdiag(model12)
tsdiag(model13)
tsdiag(model14)
tsdiag(model15)

#Peramalan dengan model terbaik
prediksi = forecast(model7, h = 23)
prediksi

#Fitting model
data.fitted=fitted(model7)
data.fitted

#Plot data aktual dan hasil peramalan
plot(prediksi)

#AKURASI PERAMALAN
mape=mean(abs(data.ts-(data.fitted))/(data.ts))*100
mape
akurasi=100-mape
akurasi

```

### Lampiran 3 *Script Program R Metode (ELM)*

```
library(TStools)
library(tsutils)
library(nnfor)
library(tseries)
library(thief)
library(forecast)
data <- read.csv(file.choose(),header=TRUE, sep=";")
data
View(data)
ts.data=ts(data$Buruh.Pabrik, frequency=12, start=c(2016,1))
ts.data

##pembagian training dan testing
train=ts(ts.data[1:58],start = c(2016,1),frequency = 12)
train
test=ts(ts.data[59:72],start = c(2020,11),frequency = 12)
test
set.seed(123)

fit1<-elm (train, hd = NULL , type = c("lasso", "ridge","step",
"lm"),
          reps = 20,comb = c("median", "mean", "mode"),lags =
NULL,
          keep = NULL, difforder = 0, outplot = c(TRUE),
          sel.lag = c(FALSE),direct =
c(FALSE/TRUE),allow.det.season = c(FALSE),
          xreg = NULL,xreg.lags = NULL,xreg.keep = NULL,barebone
= c(FALSE),
          retrain = c(TRUE))
frcl <- forecast(fit1, h=23, ip=TRUE)
frcl
accuracy(frcl, test)
plot(fit1)
plot(frcl)
fitted(fit1)
training = fit1$net$data
training
write.csv(training,"/Users/andininuramalina/Documents/SEMESTER
7/SKRIPSI/data skripsi/test.csv")

str(fit1)
summary(data)
```