

Prediksi Mahasiswa Baru Universitas Papua Menggunakan Autoregressive Integrated Moving Average

Christian Dwi Suhendra¹, Lion Ferdinand Marini², Ana Sarungallo^{3*}

^{1,2,3} Fakultas Teknik, Universitas Papua
Jl. Gunung Salju, Amban, Manokwari, Papua Barat, Indonesia

e-mail: ¹c.suhendra@unipa.ac.id, ²l.marini@unipa.ac.id, ^{3*}anasarungallo2019051@gmail.com

Informasi Artikel

Diterima: 15-07-2023

Direvisi: 14-09-2023

Disetujui: 19-09-2023

Abstrak

Perguruan tinggi sangat memperhatikan penerimaan mahasiswa baru sebagai indikator kemajuan dan pertumbuhan institusi. Namun, fluktuasi jumlah penerimaan mahasiswa baru dapat menjadi kendala dalam perencanaan dan pengambilan keputusan. Penelitian ini bertujuan untuk menerapkan metode Autoregressive Integrated Moving Average (ARIMA) dalam menghitung prediksi jumlah mahasiswa baru pada Universitas Papua. Oleh karena itu, penelitian ini menggunakan metode ARIMA untuk meramalkan jumlah mahasiswa baru tahun 2023 dengan memanfaatkan data historis dari tahun 2017 hingga 2022. Hasil analisis menggunakan R Studio menunjukkan bahwa model terbaik adalah ARIMA (11,0,12) dengan nilai error terendah. Penelitian ini memberikan manfaat bagi peneliti dalam memahami metode peramalan menggunakan ARIMA dan juga memberikan informasi yang berguna bagi Universitas Papua dalam perencanaan strategis untuk meningkatkan kualitas dan minat calon mahasiswa baru.

Kata Kunci: *Prediksi, Metode ARIMA, R Studio*

Abstract

Universities pay great attention to the acceptance of new students as an indicator of the progress and growth of the institution. However, fluctuations in the number of new student admissions can be an obstacle in planning and decision making. This study aims to apply the Autoregressive Integrated Moving Average (ARIMA) method in calculating predictions for the number of new students at the University of Papua. Therefore, this study uses the ARIMA method to predict the number of new students in 2023 by utilizing historical data from 2017 to 2022. The results of the analysis using R Studio show that the best model is ARIMA (11,0,12) with the lowest error value. This research provides benefits for researchers in understanding forecasting methods using ARIMA and also provides useful information for the University of Papua in strategic planning to improve the quality and interest of prospective new students.

Keywords: *Prediction, ARIMA Method, R Studio*

1. Pendahuluan

Perguruan tinggi merupakan salah satu lembaga lanjutan pendidikan menengah yang diselenggarakan bagi calon mahasiswa yang dipersiapkan untuk memperoleh keahlian akademis dan profesional dalam penerapan pengabdian kepada masyarakat terlebih dalam dunia kerja (Yordan et al., 2019). Mahasiswa adalah salah satu bagian penting dari beberapa aspek dalam proses pembelajaran pada suatu perguruan tinggi (Rianto & Yunis, 2021). Calon mahasiswa yang akan masuk pada perguruan tinggi, tentu menginginkan perguruan tinggi yang terbaik, baik dari segi fasilitas, akademik, dan prestasi yang menjadi pertimbangan bagi para calon mahasiswa, agar nantinya dapat menyelesaikan dunia perkuliahan dengan cepat

dengan harapan akan mendapatkan pekerjaan sesuai dengan yang diinginkan.

Perkembangan dunia pendidikan perguruan tinggi dipengaruhi oleh minat masyarakat, terutama minat yang lebih besar yaitu potensi mahasiswa untuk menuntut ilmu pada suatu perguruan tinggi, semakin besar minatnya perlu diimbangi dengan pengembangannya sumber daya manusia, sarana dan prasarana (Ritonga & Atmojo, 2018). Banyaknya mahasiswa baru yang masuk pada perguruan tinggi menjadi salah satu penentu kemajuan perguruan tinggi tersebut. Semakin meningkatnya jumlah mahasiswa baru, maka semakin baik keberadaan perguruan tinggi tersebut. Oleh karena itu perguruan tinggi melakukan berbagai cara dan strategi agar



mencapai target yang diinginkan. Namun terdapat beberapa kendala yang dapat menjadi hambatan sehingga strategi tersebut tidak tepat sasaran. Maka untuk mencapai target, minat serta kualitas calon mahasiswa baru dapat diatasi dengan melakukan peramalan (*Forecasting*) (Ritonga & Atmojo, 2018).

Penerimaan mahasiswa baru merupakan kegiatan utama yang dilakukan oleh sebuah perguruan tinggi secara berkala (Niswatin, 2016). Universitas Papua (UNIPA) adalah salah satu perguruan tinggi negeri di Indonesia yang terletak di Manokwari tepatnya pada provinsi Papua Papua Barat. Hingga tahun 2023, terdapat 54 program studi dengan 13 jumlah fakultas dan 1 pasca sarjana yang ada pada Universitas Papua. Mahasiswa yang mendaftar diterima melalui 3 jalur seleksi yaitu SNMPTN, SBMPTN, dan jalur mandiri yang terbagi atas dua jalur (jalur sesama dan jalur lokal). Jumlah mahasiswa baru yang diterima setiap tahunnya akan mempengaruhi proses belajar mengajar, kelas yang digunakan, laboratorium sebagai pendukung kegiatan praktikum mahasiswa. Dengan jumlah penerimaan mahasiswa baru yang tidak stabil maka dibutuhkan sebuah sistem untuk memprediksi tingkat penerimaan mahasiswa baru untuk semester berikutnya agar hasil peramalan dapat mendukung dalam pengambilan keputusan untuk operasional perkuliahan (Budiarto et al., 2020).


Peramalan (*forecasting*) merupakan proses yang dilakukan untuk memperkirakan suatu variabel pada masa mendatang dengan melibatkan data pada masa lampau kemudian memproyeksikannya menggunakan suatu model sistematis (Sinaga et al., 2018). Peramalan selalu menjadi pilihan terdepan yang dimanfaatkan sebagai pengambilan keputusan dan perencanaan (Petropoulos et al., 2022). Pada penelitian ini, peneliti ingin melakukan peramalan data yang bersifat runtun waktu berupa jumlah mahasiswa yang diterima pada UNIPA. Analisis runtun waktu (*time series*) adalah salah satu metode analisis kuantitatif yang mengamati variabel pada interval waktu ruang yang sama untuk mengetahui atau memprediksi suatu kondisi di masa yang akan datang (Anggraini et al., 2019).

Peramalan tidak memberikan jawaban yang pasti tentang apa yang akan terjadi di masa depan, namun berusaha memberikan hasil terdekat yang mungkin akan terjadi (Fibriani, 2014). Dengan meramalkan, pihak UNIPA dapat menggunakan sebagai acuan atau strategi apa yang akan diterapkan apabila jumlah mahasiswa pada periode mendatang mengalami kenaikan maupun penurunan.

Metode Peramalan yang digunakan merupakan metode yang sesuai dengan kondisi

data yang telah diperoleh peneliti. Metode tersebut sering digunakan untuk peramalan atau prediksi yang mencakup trend, musiman, dan non-musiman (As'ad et al., 2017). Metode yang dimaksud adalah gabungan antara metode *Autoregressive* (AR) dan *Moving Average* (MA). Pada penelitian ini akan menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) sehingga penelitian ini berjudul "Peramalan Mahasiswa Baru Menggunakan *Autoregressive Integrated Moving Average* (ARIMA) Pada Universitas Papua".

2. Metode Penelitian



Gambar 1 Alur Penelitian

1. Pengumpulan Data

Pelaksanaan penelitian ini dimulai pada bulan November 2022 hingga Januari 2023. Penelitian dilakukan di Universitas Papua dengan memperoleh data pada Biro Perencanaan Akademik dan Kemahasiswaan (BPAK) yang beralamat di Jl. Gunung Salju Amban.

Metode yang dilakukan oleh seorang peneliti untuk dapat mengumpulkan data dan informasi yang berguna sebagai fakta pendukung yaitu teknik pengumpulan data. Teknik pengumpulan data terbagi menjadi beberapa teknik yaitu observasi, kuisisioner, wawancara, studi literatur dan studi dokumen. Teknik pengumpulan data dalam penelitian ini menggunakan teknik studi dokumen yang sumbernya berasal dari sumber tertulis (buku), gambar, film dan sistem informasi. Sumber data yang diteliti didapatkan berdasarkan data mahasiswa pada Biro Perencanaan Akademik dan Kemahasiswaan (BPAK).

2. Pemodelan Data

Jenis data dibagi menjadi dua, yaitu data kuantitatif dan data kualitatif. Data kuantitatif

adalah data yang berbentuk angka atau bilangan sehingga dapat diolah secara numerik dengan akurat, sedangkan data kualitatif merupakan data yang tidak disajikan dalam bentuk angka atau bilangan. Jenis data yang digunakan dalam penelitian ini adalah data kuantitatif yang dapat dilihat pada Tabel 1.

Tabel 1. Data Mahasiswa Berdasarkan Fakultas 2017-2022

Tahun	2017	2018	2019	2020	2021	2022
Fakultas Teknologi Pertanian	89	82	61	75	63	71
Fakultas Pertanian	264	259	277	164	131	102
Fakultas Kehutanan	290	291	252	150	178	171
Fakultas Peternakan	100	142	99	67	43	73
Fakultas Matematika Dan Ilmu Pengetahuan Alam	134	139	125	64	46	32
Fakultas Perikanan Dan Ilmu Kelautan	270	184	190	141	106	85
Fakultas Sastra Dan Budaya	237	197	2	94	99	121
Fakultas Ekonomi Dan Bisnis	151	331	198	157	318	383
Fakultas Teknik	293	275	289	290	244	306
Fakultas Teknik Pertambangan Dan Perminyakan	137	211	209	140	126	134
Fakultas Keguruan Dan Ilmu Pendidikan	353	288	350	142	115	144
Fakultas Kedokteran	40	37	48	49	56	63

3. Rancangan Sistem Dengan ARIMA Menggunakan *R-Shiny*

a. Dataset Prediksi Mahasiswa Universitas Papua

Dataset merupakan tampilan yang berisikan data dari mahasiswa yang diunggah dan belum diolah. Selanjutnya data ini akan ditampilkan dan data ini yang akan diolah untuk mendapatkan prediksi mahasiswa Universitas Papua.

b. Stasioneritas

Data *time series* terbagi ke dalam dua, yaitu data stasioner dan non stasioner. Data *time series* dikatakan stasioner jika tidak memiliki *trend* yang berarti rata-rata data konstan selama periode waktu T . Sedangkan data *time series* dikatakan non stasioner jika rata-rata atau varians data tidak konstan selama waktu T . Jika rata-rata data *time series* tidak konstan, maka *time series* dikatakan non stasioner pada rata-rata (*mean*). Jika varians data *time series* tidak konstan, maka *time series* dikatakan non stasioner pada varians (*variance*) (Adhikari & Agrawal, 2013).

c. Analisis Deret Waktu

Dalam menentukan metode peramalan pada deret waktu perlu diketahui pola dari data tersebut, sehingga peramalan data dapat dilakukan dengan metode yang sesuai. Tahapan penting dalam memilih suatu metode deret waktu adalah dengan mempertimbangkan jenis pola data. Adapun jenis pola data adalah sebagai berikut. (1) Pola Horizontal adalah pola data yang berfluktuasi disekitar rata-rata atau secara umum pola ini disebut pola konstan yang berarti pola ini tidak memiliki trend yang meningkat atau menurun secara sistematis sepanjang waktu (2) Pola Musimam memiliki gerakan pola-pola tetap atau ide entik dari waktu ke waktu yang berulang dalam jangka pendek. Jenis pola ini biasanya berlangsung dalam periode tahunan, diukur dalam mingguan, bulanan, ataupun triwulanan. (3) Pola Trend Jenis pola mengandung trend apabila deret data menunjukkan pertumbuhan yang stabil ke atas atau penurunan ke bawah selama beberapa periode waktu berturut-turut. Trend secara bebas dapat didefinisikan sebagai "perubahan jangka panjang pada tingkat rata-rata". (4) Pola Siklis memiliki gerakan naik turun disekitar garis trend dalam jangka panjang. Gerakan siklis ini bisa berulang setelah jangka waktu tertentu misalnya 3 tahun, 5 tahun atau bahkan lebih, tetapi dapat juga tidak berulang dalam jangka waktu yang sama

d. Pembedaan (*Differencing*)

Transformasi *differencing* dilakukan jika data *time series* non stasioner pada *mean*. Untuk menghilangkan ketidakstasioneran dapat dilakukan perbedaan (*differencing*) non musiman untuk data yang tidak mengandung pola musiman sedangkan untuk pola data yang mengandung musiman dapat dilakukan *differencing* musiman.

Proses *differencing* yaitu mengurangi antara data Z_t dengan data Z_{t-1} . *Differencing* dapat dilakukan dengan menggunakan operator *shift* mundur (*backward shift*) B . Operator *backward shift* atau *backshift* digunakan untuk memindahkan indeks waktu pengamatan mundur dengan satu interval. *Differencing* pertama (*first differencing*) menggunakan *backward shift* sebagai berikut.

$$BZ_t = Z_{t-1} \quad (1)$$

Dimana:

- B = Perbedaan (*backward shift*)
- Z_t = Nilai Z pada periode ke t
- Z_{t-1} = Nilai Z pada periode ke $t-1$

Notasi B yang dipasangkan dengan Z_t akan menggeser data tersebut 1 periode ke belakang. Sebagai contoh, apabila suatu data *time series* tidak stasioner maka data tersebut dapat dibuat lebih mendekati stasioner. Dengan begitu, persamaan *first differencing* adalah sebagai berikut

$$\Delta Z_t = Z_t - Z_{t-1} \quad (2)$$

Dimana:

- ΔZ_t = *Differencing* pertama (*first differencing*)

Terdapat hubungan antara operator *differencing* dengan operator *backshift*, sehingga dengan menggunakan operator *backward shift* B maka ΔZ_t dapat ditulis menjadi:

$$\Delta Z_t = Z_t - Z_{t-1} = Z_t - BZ_t = (1 - B) Z_t \quad (3)$$

Differencing pertama pada Persamaan (3) dapat dinotasikan oleh $(1 - B)$, demikian pula dengan *differencing* orde kedua yang merupakan *differencing* pertama dari hasil *idifferencing* pertama sebelumnya dapat ditulis menggunakan operator *backshift* sebagai berikut:

$$\begin{aligned} \Delta^2 &= \Delta Z_t - \Delta Z_{t-1} \\ &= (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) \\ &= Z_t - 2Z_{t-1} + Z_{t-2} \\ &= (1 - 2B + B^2)Z_t \\ &= (1 - B)^2 Z_t \end{aligned} \quad (4)$$

Dimana:

$$\Delta^2 Z_t = \text{Differencing orde kedua}$$

Differencing orde kedua pada Persamaan (4) dinotasikan $(1-B)^2$. Secara umum, apabila terdapat *differencing* orde ke- d untuk mencapai stasioneritas dapat dinotasikan sebagai berikut:

$$\Delta^d Z_t = (1 - B)^d Z_t \quad (5)$$

Differencing orde ke dua dilakukan jika data masih non stasioner setelah dilakukan *differencing* pertama. Namun, kebanyakan data sudah stasioner setelah dilakukan *differencing* pertama atau *first differencing*.

e. Uji ACF dan Uji PACF

Autocorrelation Function (ACF) Fungsi autokorelasi merupakan hubungan atau korelasi terhadap diri sendiri. Nilai Autokorelasi didefinisikan sebagai korelasi antar suatu deret waktu dengan deret waktu itu sendiri pada selisih waktu (*lag*) 0,1,2 periode atau lebih. Pada koefisien autokorelasi runtun waktu, dengan autokorelasi menghitung dan membuat plot nilai autokorelasi dari suatu data *time series*. Dengan melihat pola *Autocorellation Function* (ACF), akan didapatkan nilai p dan q pada model ARIMA(p,d,q). Autokorelasi pada *lag* ke- k untuk suatu observasi deret waktu dapat diduga dengan koefisien autokorelasi sampel (Yordan et al., 2019). Sehingga secara sistematis dapat dinotasikan dengan:

$$r_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (7)$$

Dimana:

- r_k = Koefisien autokorelasi untuk *lag* periode ke- k
- Z_t = Nilai observasi pada periode ke- t
- Z_{t+k} = Nilai observasi pada periode ke- $(t + k)$
- \bar{Z} = Rata-rata nilai observasi

Partial Autocorrelation Function (PACF) Fungsi autokorelasi parsial merupakan hubungan antara suatu hasil observasi dengan hasil observasi tersebut. Sehingga PACF ini ialah suatu himpunan autokorelasi parsial untuk berbagai *lag* k atau ($akk; k = 1,2,3, \dots, k$) yang merupakan himpunan autokorelasi parsial untuk berbagai *lag* k . Fungsi autokorelasi parsial atau PACF digunakan untuk mengukur tingkat keeratan antara Z_t dan Z_{t-1} apabila pengaruh dari *lag* ke-1, 2, 3,... sampai $k-1$ dianggap terpisah. Autokorelasi parsial pada *lag* ke- k dinyatakan sebagai korelasi antara Z_t dan Z_{t-1} setelah dihilangkannya efek dari variabel-variabel $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$ (Rachmawati, 2020).

f. *Model Autoregressive Integrated Moving Average (ARIMA)*

Model Autoregresif (AR) Asumsi yang dimiliki pada model ini yaitu data periode sekarang dipengaruhi oleh data pada periode sebelumnya. Disebut model *Autoregressive* karena pada model ini diregresikan terhadap nilai-nilai sebelumnya dari variabel itu sendiri (Halim, 2006). Model *Autoregressive* dengan ordo p disingkat menjadi AR (p) atau ARIMA (p, 0, 0) dengan model:

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} - a_t \quad (8)$$

- Z_t = deret waktu stasioner
- μ = Konstanta
- Z_{t-p} = variabel bebas
- ϕ_p = koefisien parameter *autoregressive* ke-p
- a_t = sisaan pada saat ke-t

Model Moving Average (MA) Model MA pertama kali diperkenalkan pada tahun 1973 oleh Slutsky, dengan ordo q ditulis MA (q) atau ARIMA (0, 0, q) yang kemudian dikembangkan oleh Wadsworth pada tahun 1989. Model dari Moving Average yaitu:

$$Z_t = \mu + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (9)$$

- Z_t = deret waktu stasioner
- μ = Konstanta
- a_{t-1} = variabel bebas
- θ_q = koefisien parameter *moving average* ke-q
- a_t = sisaan pada saat ke-t

Autoregressive Moving Average (ARMA) Model ARMA merupakan model yang menggabungkan model *Autoregressive (AR)* dan model *Moving Average (MA)*. Penggabungan kedua metode ini dimaksudkan agar mendapatkan output yang lebih baik dan nilai eror yang lebih kecil (Salwa et al., 2018). Model dari ARMA yaitu:

$$Z_t = \mu + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (10)$$

- Z_t = deret waktu stasioner
- μ = Konstanta
- Z_{t-p} = variabel bebas
- ϕ_p = koefisien parameter *autoregressive* ke-p
- a_{t-1} = variabel bebas
- θ_q = koefisien parameter *moving average* ke-q
- a_t = sisaan pada saat ke-t

Model *Autoregressive Integrated Moving Average (ARIMA)* pertama kali dipopulerkan oleh George Box dan Gwilym Jenkins pada awal

tahun 1970-an. Model ARIMA merupakan model dari ARMA yang diintegrasikan disebabkan data yang tidak stasioner sehingga dilakukan proses differencing sebanyak d (Shumway, R. H., & Stoffer, 2017). Secara umum notasi dalam model ARIMA yang telah dipopulerkan oleh Box dan Jenkins sebagai berikut:

$$\phi_p(B)D^d Z_t = \mu + \theta_q(B) a_t \quad (11)$$

- ϕ_p = koefisien parameter *autoregressive* ke-p
- θ_q = koefisien parameter *moving average* ke-q
- B = operator *backshift*
- D = *Differencing*
- μ = Konstanta
- a_t = sisaan pada saat ke-t
- p = derajat *autoregressive*
- d = tingkat proses *differencing*
- q = Derajat *moving average*


g. R-Shiny

Framework aplikasi pengembangan web yang mana kebutuhan *environment* aplikasi tersebut menggunakan bahasa pemrograman R disebut R-Shiny. Aplikasi yang dimiliki oleh R Shiny sangat mudah dan reliabel penggunaannya sebagai pengembangan web karena langsung terintegrasi dengan bahasa R. Dengan aplikasi ini, sistem yang dibangun diharapkan akan menjadi lebih dinamis dan mudah digunakan kedepannya bagi para user. R-Shiny juga dapat digunakan dalam membantu menganalisis web yang interaktif tanpa harus membutuhkan keahlian dalam HTML, CSS, atau *JavaScript*.

R-Shiny dibedakan menjadi 2 kelompok yaitu server dan user interface (ui) (Made Tirta et al., 2014). Bagian otak dari sebuah program yang fungsinya dapat melakukan simulasi analisis data yang selanjutnya akan dikirimkan ke bagian output disebut dengan server. Dokumen file server terdiri dari dua bagian yaitu preambule dan server shiny yang akan disimpan dalam file server R. Preambule memiliki beberapa perintah yang dapat mengaktifkan *library* terikat, mengaktifkan data yang dibutuhkan oleh pengguna, mengaktifkan data simulasi dan dapat mengaktifkan fungsi-fungsi yang sifatnya global. Sedangkan *User Interface (UI)* digunakan untuk membuat tampilan dari aplikasi atau GUI (*Graphical User Interface*). Pada bagian UI ini, *syntax* ditulis dan disimpan dalam file ui R. Komponen dalam file ui R merupakan setiap menu utama dari masing-masing yang akan memiliki submenu (tabPanel), menjadi control input (sidebarPanel) dan tampilan output itu sendiri (mainPanel)

h. Usulan Rancangan Sistem

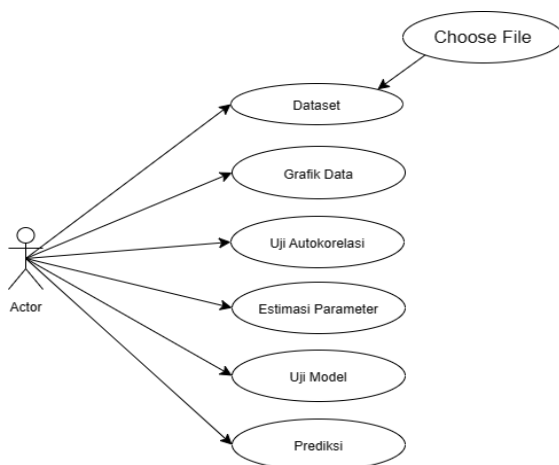
Untuk Alur dari sistem yang akan dikembangkan dapat dilihat pada gambar berikut.



Gambar 2. Alur Sistem

i. Use Case Diagram

Use case diagram digunakan untuk mendeskripsikan interaksi antara aktor atau pengguna dan sistem. Aktor dapat mengakses beberapa menu didalam sistem yang diantaranya menu dataset, grafik data, uji autokorelasi, estimasi parameter dan prediksi.



Gambar 3. Use Case Diagram Sistem

3. Hasil dan Pembahasan

Pada bagian hasil merupakan implementasi dari Pemrograman menggunakan R-Shiny untuk melakukan prediksi dengan ARIMA. Hasil dari implementasi adalah sebagai berikut :

3.1 Dataset

Waktu	Mahasiswa
2017 1	89,00
2017 2	264,00
2017 3	290,00
2017 4	100,00
2017 5	134,00
2017 6	270,00
2017 7	237,00
2017 8	151,00
2017 9	293,00
2017 10	137,00
2017 11	353,00
2017 12	40,00
2018 1	82,00
2018 2	259,00
2018 3	291,00
2018 4	142,00
2018 5	139,00


Gambar 4. Dataset

Gambar 4 merupakan *dataset* mahasiswa yang di *upload* dengan format excel dan terdiri dari tahun serta jumlah mahasiswa untuk masing-masing fakultas yang terdapat pada Universitas Papua. Tahun *dataset* yang digunakan pada penelitian ini dimulai dari tahun 2017 hingga 2022 untuk 12 fakultas. Pada penelitian ini peneliti melakukan pengkodean untuk memberikan identifikasi unik atau nomor yang dapat digunakan untuk merujuk pada subjek atau variabel yang terlibat dalam penelitian. Jenis pengkodean yang digunakan yaitu kode variabel dengan menggantikan nama variabel dengan angka, dimana angka yang dimulai dari 1 hingga 12 merupakan urutan untuk nama fakultas yang terdapat pada Universitas Papua. Berikut rincian pengkodean yang dimaksud pada penelitian.

Tabel 2. Kode Variabel

Kode	Nama Fakultas
1	Fakultas teknologi pertanian
2	Fakultas pertanian
3	Fakultas kehutanan
4	Fakultas peternakan
5	Fakultas matematika dan ilmu pengetahuan alam
6	Fakultas perikanan dan ilmu kelautan
7	Fakultas sastra dan budaya
8	Fakultas ekonomi dan bisnis
9	Fakultas teknik
10	Fakultas teknik pertambangan dan perminyakan
11	Fakultas keguruan dan ilmu pendidikan
12	Fakultas kedokteran

3.2 Grafik Data



Gambar 5. Grafik Data


Langkah awal dalam analisis deret waktu adalah membuat plot data asli secara grafis, data jumlah mahasiswa pada Universitas Papua mulai dari tahun 2017 hingga 2022 dapat dilihat melalui plot *time series* pada Gambar 5

Gambar 5 dapat dilihat bahwa grafik yang dihasilkan menunjukkan karakteristik data yang stasioner dalam mean. Garis rata-rata data tetap sejajar dengan sumbu horizontal, menandakan ketidakberubahannya seiring waktu. Hal ini menunjukkan bahwa tidak ada tren atau perubahan sistematis yang signifikan dalam nilai rata-rata data sepanjang rentang waktu yang diamati. Selain itu, fluktuasi atau variasi data di sekitar nilai rata-rata cenderung relatif konstan sepanjang waktu. Ini dapat dilihat dari adanya fluktuasi yang relatif serupa disekitar garis rata-rata tanpa pola atau pola khusus yang terlihat.

3.3 Uji Autokorelasi


Setelah data stasioner dalam mean kemudian dilakukan pengujian autokorelasi dengan menggunakan ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*). Kedua fungsi ini memberikan informasi tentang hubungan antara nilai saat ini dengan nilai-nilai sebelumnya dalam deret waktu. Informasi dari grafik ACF dan PACF dapat membantu dalam memodelkan dan mendiagnosis deret waktu. Pola grafik ini dapat digunakan untuk memilih model AR (*Autoregressive*), MA (*Moving Average*), atau ARMA (*Autoregressive Moving Average*) yang sesuai untuk menggambarkan hubungan autokorelasi dalam data.

Mengidentifikasi model ARIMA yang akan digunakan dalam peramalan dapat diperoleh dengan melihat plot ACF dan PACF yang ditunjukkan pada gambar 6..



Gambar 6. Plot ACF

Mahasiswa

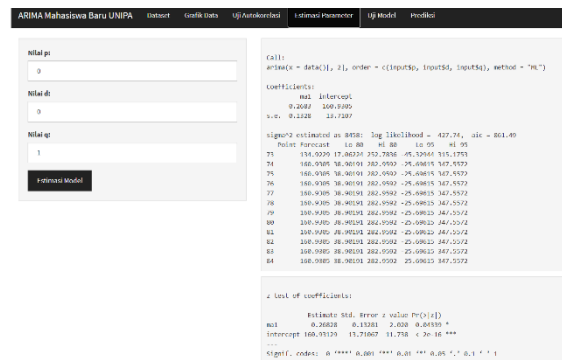


Gambar 7. Plot PACF

Berdasarkan Gambar 6 dapat dilihat bahwa pada plot ACF terjadi *cut off* setelah lag 12 sehingga dapat diidentifikasi model MA(12). Hal yang sama terjadi pada Gambar 7 *cut off* setelah lag 12 sehingga dapat diidentifikasi memiliki model AR(12) dengan data yang tidak melalui proses differencing sehingga diperoleh 25 model yang mungkin dapat dilakukan untuk memprediksi data yaitu: (12,0,0), (12,0,1), (12,0,2), (12,0,3), (12,0,4), (12,0,5), (12,0,6), (12,0,7), (12,0,8), (12,0,9), (12,0,10), (12,0,11), (12,0,12), (0,0,12), (1,0,12), (2,0,12), (3,0,12), (4,0,12), (5,0,12), (6,0,12), (7,0,12), (8,0,12), (9,0,12), (10,0,12), (11,0,12).

3.4 Estimasi Parameter

Berdasarkan model yang diperoleh pada uji autokorelasi yaitu sebanyak 25 model, maka selanjutnya akan dilakukan estimasi parameter pada setiap model yang ada dengan melihat nilai p-value-nya yaitu <0,05.



Gambar 8. Estimasi Parameter

Berdasarkan hasil estimasi parameter dari 25 model dugaan awal yang memungkinkan, pada Tabel 4.1 ditampilkan model yang lolos uji signifikan berdasarkan p-value dimana nilai p-value-nya yaitu <0,05.

Tabel 3. Daftar Nilai Estimasi Model Signifikan

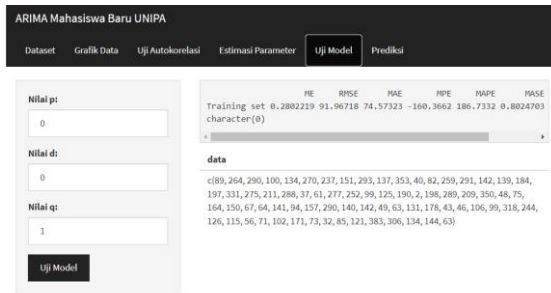
Arima Model	Parameter	Estimasi	P-value
(0,0,1)	MA 1	0.26828	0.04339

Arima Model	Parameter	Estimasi	P-value	Arima Model	Parameter	Estimasi	P-value
(2,0,2)	AR 1	0.938281	< 2.2e-16	AR 9	0.5059	0.003154	
	AR 2	-0.96838	< 2.2e-16	AR 10	-0.49089	2.96E-07	
	MA 1	-	< 2.2e-16	AR 11	0.53279	7.53E-07	
	MA 2	0.836129	< 2.2e-16	MA 1	-1.05262	3.40E-09	
(2,0,3)	MA 2	0.999973	< 2.2e-16	MA 2	1.39541	7.88E-16	
	AR 1	1.345952	< 2.2e-16	MA 3	-1.88424	1.71E-07	
	AR 2	-	< 2.2e-16	MA 4	1.68145	0.00099	
	MA 1	-	4.06E-13	MA 5	-1.82475	0.013447	
(4,0,4)	MA 2	0.451551	0.03777	MA 6	1.4297	0.039806	
	MA 3	0.36038	0.01113	MA 7	-1.03968	0.00319	
	AR 1	-	0.03953	MA 8	0.95128	7.60E-16	
	AR 2	0.142801	< 2.2e-16	AR 1	0.817112	< 2.2e-16	
(5,0,5)	AR 3	0.883682	< 2.2e-16	AR 2	-	1.33E-07	
	AR 4	-	0.03713	AR 3	0.710953	9.76E-07	
	AR 1	0.161222	< 2.2e-16	AR 4	0.70483	2.24E-14	
	AR 2	0.896037	< 2.2e-16	AR 5	-0.73946	1.48E-10	
(11,0,8)	MA 1	0.429784	6.69E-06	AR 6	0.706708	1.64E-06	
	MA 2	0.973086	< 2.2e-16	AR 7	-	3.96E-07	
	MA 3	0.42978	8.45E-06	AR 8	0.630371	1.64E-06	
	MA 4	0.999922	< 2.2e-16	AR 9	0.666032	3.96E-07	
(11,0,8)	AR 1	0.917573	< 2.2e-16	AR 10	-	8.93E-13	
	AR 2	-	< 2.2e-16	AR 11	0.807916	8.93E-13	
	AR 3	0.983668	< 2.2e-16	AR 12	0.755592	1.08E-10	
	AR 4	0.91642	< 2.2e-16	MA 1	-	2.39E-08	
(11,0,8)	AR 5	-	< 2.2e-16	MA 2	0.730511	2.39E-08	
	MA 1	0.969363	< 2.2e-16	MA 3	0.759048	4.38E-15	
	MA 2	0.933858	< 2.2e-16	MA 4	-	3.46E-05	
	MA 3	-	1.31E-06	MA 5	0.763048	3.46E-05	
(11,0,8)	MA 4	0.785329	1.31E-06	MA 6	0.559508	0.027553	
	MA 5	0.908849	5.25E-07	MA 7	-	0.010732	
	MA 6	-	5.01E-07	MA 8	0.721952	0.010732	
	MA 7	0.767755	5.01E-07	MA 9	0.588166	0.013549	
(11,0,8)	MA 8	0.928601	1.68E-11	MA 10	-	0.042935	
	MA 9	-	0.000143	MA 11	0.543582	0.042935	
	AR 1	1.12762	< 2.2e-16	MA 12	0.553833	0.03902	
	AR 2	-1.38895	2.59E-16	MA 1	-	0.012643	
(11,0,8)	AR 3	1.63044	1.28E-12	MA 2	0.650049	0.012643	
	AR 4	-1.62546	6.78E-09	MA 3	0.970691	0.000125	
	AR 5	1.62672	1.48E-07	MA 4	-	0.020651	
	AR 6	-1.29976	0.000508	MA 5	0.584133	0.020651	
(11,0,8)	AR 7	1.07236	0.002477	MA 6	0.542675	0.048507	
	AR 8	-0.84722	0.027035	MA 7	-	0.000543	
	AR 9	-	0.000543	MA 8	0.660304	0.000543	
	AR 10	-	0.000526	MA 9	0.65234	0.000526	

3.5 Uji Model

Berdasarkan Tabel 2 menampilkan 7 model yang parameternya signifikan, sehingga ketujuh model tersebut dimasukkan ke dalam kemungkinan model terbaik. Pada tahap ini model-model tersebut akan diuji untuk mencari nilai error yang terkecil untuk selanjutnya dapat digunakan sebagai model terbaik untuk memprediksi jumlah mahasiswa. Peneliti

menggunakan RMSE dan MAPE untuk mencari nilai error-nya.



Gambar 9. Uji Model

Pada Tabel 3 berikut dapat dilihat nilai error pada RMSE dan MAPE untuk ketujuh model serta nilai AIC (Akaike Information Criterion) dan Log Likelihood yang diperoleh pada proses sebelumnya yaitu estimasi parameter (Gambar 8) bagi setiap model yang diuji. Semakin tinggi nilai log likelihood, semakin baik model cocok dengan data. Namun, semakin banyak parameter yang digunakan, semakin kompleks model tersebut. AIC menyesuaikan log likelihood dengan jumlah paramete, dengan cara mengurangi jumlah parameter dari log likelihood. Dengan demikian, model dengan AIC yang lebih rendah dianggap lebih baik karena mampu memberikan penjelasan yang baik dengan kompleksitas yang lebih rendah.

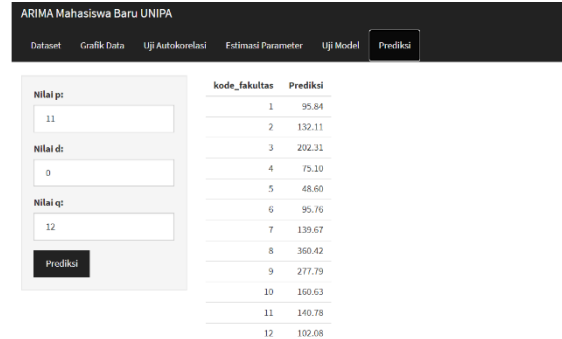
Tabel 4. Nilai Error, AIC dan Log Likelihood

ARIMA	RMSE	MAPE	AIC	Log Likelihood
(0,0,1)	91.96718	186.7332	861.49	-427.74
(2,0,2)	91.07449	183.6733	866.14	-427.07
(2,0,3)	91.00416	183.8289	868.03	-427.01
(4,0,4)	75.31496	121.8306	856.04	-418.02
(5,0,5)	73.50579	127.3411	857.13	-416.56
(11,0,8)	52.89118	130.4801	841.56	-399.78
(11,0,12)	48.57327	121.687	838.98	-394.49

Berdasarkan ketujuh model yang signifikan kemudian dipilih satu model terbaik yang memiliki nilai RMSE, MAPE, dan AIC yang terkecil serta nilai log likelihood yang terbesar. Dari Tabel 4.2 diketahui bahwa model yang memenuhi kriteria adalah model ARIMA (11,0,12).

3.6 Prediksi

Hasil prediksi jumlah mahasiswa Universitas Papua untuk tahun 2023 menggunakan model ARIMA (11,0,12) dapat dilihat pada gambar berikut.



Gambar 10. Hasil Prediksi

4. Kesimpulan

Berdasarkan analisis menggunakan R Studio dengan metode ARIMA untuk data mahasiswa pada Universitas Papua, diperoleh model terbaik yakni model ARIMA (11,0,12) dengan nilai error menggunakan RMSE sebesar 48.57327 dan MAPE sebesar 121.687. Selain memiliki nilai error terendah model ARIMA (11,0,12) juga memiliki nilai AIC terendah dari beberapa model yang memungkinkan untuk memprediksi yaitu sebesar 838.98 serta nilai log likelihood terbesar yaitu -394.49. Sehingga model ARIMA (11,0,12) dianggap sebagai model terbaik untuk prediksi dalam konteks analisis yang dilakukan dengan hasil prediksi sebagai berikut untuk tahun berikutnya dari data yang diperoleh oleh peneliti. Fakultas Teknologi Pertanian (95.84), Fakultas Pertanian (132.11), Fakultas Kehutanan (202.31), Fakuktas Peternakan (75.10), Fakultas Matematika dan Ilmu Pengetahuan Alam (48.60), Fakultas Perikanan dan Ilmu Kelautan (95.76), Fakultas Sastra dan Budaya (139.67), Fakultas Ekonomi dan Bisnis (360.42), Fakultas Teknik (277.79), Fakultas Teknik Pertambangan dan Perminyakan (160.63), Fakultas Keguruan dan Ilmu Pendidikan (140.78), Fakultas Kedokteran (102.08). Berdasarkan hasil penelitian, penulis memberi saran kepada peneliti selanjutnya diharapkan menggunakan metode *time series* lainnya untuk membandingkan tingkat akurasi prediksi yang dihasilkan.

Referensi

- Adhikari, R., & Agrawal, R. K. (2013). An Introductory Study on Time Series Modeling and Forecasting Ratnadip Adhikari R. K. Agrawal. *ArXiv Preprint ArXiv:1302.6613, 1302.6613*, 1–68.

- Anggraini, M., Goejantoro, R., & Nasution, Yuki N. (2019). Peramalan Kebutuhan Bahan Baku Plat Besi Menggunakan Metode Runtun Waktu Autoregressive Integrated Moving Average (ARIMA) dan Meminimumkan Biaya Total Persediaan dari Hasil Peramalan Menggunakan Metode Period Order Quantity (POQ) (Studi Kasus: CV. Isakutam. *Jurnal Eksponensial*, 10(1), 1–10.
- As'ad, M., Wibowo, S. S., & Sophia, E. (2017). Peramalan Jumlah Mahasiswa Baru Dengan Model Autoregressive Integrated Moving Average (Arima). *J I M P - Jurnal Informatika Merdeka Pasuruan*, 2(3), 20–33.
- Budiarto, N., Kom, M., Wibowo, A., Kom, S., Kom, M., Wijanarko, S., Kom, S., Kom, M., Pratama, E. B., Kom, M., Yusri, A., & Kom, M. (2020). *Forecasting Model of Student Admission in XYZ University with Arima*. 7(1), 1–13.
- Fibriani, C. (2014). *Analisis Mahasiswa Baru Menggunakan Metode Arima*. November.
- Halim, S. (2006). *Diklat - Time Series Analysis Prakata*. January.
- Made Tirta, I., Fmipa, J. M., & Jember, U. (2014). *Prosiding Seminar Nasional Matematika*.
- Niswatin, R. K. (2016). *Sistem Seleksi Penerimaan Mahasiswa Baru Menggunakan Metode Weighted Product (WP)*. 6–7.
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Cyrino Oliveira, F. L., De Baets, S., Dokumentov, A., ... Ziel, F. (2022). Forecasting: theory and practice. *International Journal of Forecasting*, 38(3), 705–871.
- Rachmawati, A. K. (2020). Peramalan Penyebaran Jumlah Kasus Covid19 Provinsi Jawa Tengah dengan Metode ARIMA. *Zeta - Math Journal*, 6(1), 11–16.
- Rianto, M., & Yunis, R. (2021). Analisis Runtun Waktu Untuk Memprediksi Jumlah Mahasiswa Baru Dengan Model Random Forest. *Paradigma - Jurnal Komputer Dan Informatika*, 23(1).
- Ritonga, A. S., & Atmojo, S. (2018). Pengembangan Model Jaringan Syaraf Tiruan untuk Memprediksi Jumlah Mahasiswa Baru di PTS Surabaya (Studi Kasus Universitas Wijaya Putra). *Jurnal Ilmiah Teknologi Informasi Asia*, 12(1), 15.
- Salwa, N., Tatsara, N., Amalia, R., & Zohra, A. F. (2018). Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average). *Journal of Data Analysis*, 1(1), 21–31.
- Shumway, R. H., & Stoffer, D. (2017). Time Series Analysis and Its Applications. In *North-Holland Mathematics Studies* (Vol. 74, Issue C).
- Sinaga, E., Sembiring, A. S., & Limbong, R. (2018). *Mahasiswa Dengan Metode Auto Regressive Integrated Moving Average (Arima) (Studi Kasus : Prodi Ti Stmik Budidarma Medan)*. 6, 73–78.
- Yordan, A., Putri, T. N., & Lamkaruna, D. H. (2019). Peramalan Penerimaan Mahasiswa Baru Universitas Samudra Menggunakan Metode Regresi Linear Sederhana. *Jurnal Teknik Informatika (J-Tifa)*, 2(1), 21–27.