

Perbandingan Model ARIMA dan ANN dalam Memprediksi Mahasiswa Baru

Hairani, I Nyoman Switrayana, Saifuddin Zuhri

Univeritas Bumigora, Mataram, Indonesia

Correspondence : e-mail: saifuddin339@gmail.com

Abstrak

Prediksi jumlah mahasiswa baru merupakan aspek krusial dalam perencanaan strategis perguruan tinggi, yang mempengaruhi alokasi sumber daya, perencanaan infrastruktur, dan pengembangan program akademik. Penelitian ini mengkaji penerapan dua metode prediksi time series yang berbeda: *AutoRegressive Integrated Moving Average (ARIMA)* dan *Artificial Neural Network (ANN)* untuk memprediksi jumlah mahasiswa baru. Menggunakan data historis penerimaan mahasiswa selama 6 tahun (2019-2024), penelitian ini membandingkan akurasi prediksi kedua metode dalam konteks perencanaan perguruan tinggi. Hasil penelitian menunjukkan bahwa metode ANN memberikan akurasi prediksi yang lebih tinggi dengan nilai MAPE 11.65% dibandingkan ARIMA dengan MAPE 17.9%. Evaluasi performa model dilakukan menggunakan metrik evaluasi MSE (Mean Absolute Error), RMSE (Root Mean Square Error), dan MAE (Mean Absolute Error). Model Artificial Neural Network menunjukkan performa yang lebih baik dalam memprediksi jumlah mahasiswa baru dengan tingkat akurasi yang dapat diterima untuk keperluan perencanaan institusi. Namun, ARIMA memberikan interpretabilitas yang lebih baik dalam memahami pola seasonality dan trend jangka panjang.

Kata kunci: ARIMA, Artificial Neural Network, Prediksi Mahasiswa, Time Series, Perencanaan Perguruan Tinggi.

Abstract

Predicting the number of new students is a crucial aspect of higher education strategic planning, influencing resource allocation, infrastructure planning, and academic program development. This study examines the application of two different time series prediction methods: *AutoRegressive Integrated Moving Average (ARIMA)* and *Artificial Neural Network (ANN)* to predict the number of new students. Using historical student admission data for 5 years (2019-2024), this study compares the prediction accuracy of the two methods in the context of higher education planning. The results show that the ANN method provides higher prediction accuracy with a MAPE value of 11.65% compared to ARIMA with a MAPE of 17.9%. Model performance evaluation was conducted using the MSE evaluation metric (Mean Absolute Error), RMSE (Root Mean Square Error), under MAE (Mean Absolute Error). Model Artificial Neural Network demonstrated better performance in predicting the number of new students with an acceptable level of accuracy for institutional planning purposes. However, ARIMA provided better interpretability in understanding seasonality patterns and long-term trends.

Keywords: ARIMA, Artificial Neural Network, Student Predictions, Time Series, College Planning.

1. Pendahuluan

Penerimaan mahasiswa baru merupakan kegiatan tahunan yang krusial bagi setiap universitas, karena berdampak langsung pada keberlanjutan institusi, perencanaan akademik, dan daya saing institusi secara keseluruhan dalam lanskap pendidikan tinggi [1]. Perencanaan strategis dalam perguruan tinggi memerlukan prediksi yang akurat mengenai jumlah mahasiswa baru yang akan mendaftar pada periode mendatang. Prediksi ini menjadi dasar untuk berbagai keputusan strategis, mulai dari alokasi sumber daya manusia, perencanaan infrastruktur fisik, hingga pengembangan program studi baru [2]. Ketidakakuratan dalam prediksi dapat mengakibatkan *over-capacity* atau *under-capacity* yang berdampak pada kualitas layanan pendidikan dan efisiensi operasional. Prediksi jumlah mahasiswa baru merupakan aspek krusial dalam manajemen strategis institusi pendidikan tinggi [3]. Dalam era kompetisi global pendidikan tinggi yang semakin ketat, kemampuan untuk memprediksi dengan akurat jumlah mahasiswa baru menjadi keunggulan kompetitif yang tidak dapat diabaikan.

Data historis penerimaan mahasiswa menunjukkan pola yang kompleks, dipengaruhi oleh berbagai faktor seperti tren demografi, kondisi ekonomi, kebijakan pemerintah, dan daya saing perguruan tinggi [4]. Kompleksitas ini memerlukan pendekatan metodologi yang dapat menangkap pola linear maupun non-linear dalam data *time series* penerimaan. Model ARIMA dan variannya telah diterapkan secara luas selama setengah abad terakhir dalam bidang *forecasting time series* karena kesederhanaan matematis dan fleksibilitas aplikasinya [5]. Namun, dengan kemajuan terkini dalam pengembangan dan implementasi efisien model *artificial intelligence*, pandangan mulai berubah dengan pergeseran menuju pendekatan *machine learning* dan *deep learning*.

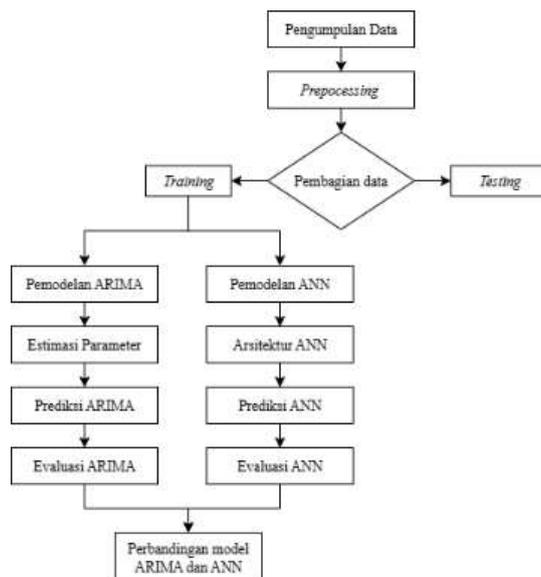
Autoregressive Integrated Moving Average (ARIMA) merupakan salah satu model linear yang populer dalam *forecasting time series* selama tiga dekade terakhir. Model ARIMA memiliki keunggulan dalam menangkap pola linear dan seasonal dalam data *time series*, serta memiliki fondasi teoritis yang kuat dalam statistik. [6] Dalam konteks prediksi enrollment mahasiswa, model ARIMA telah terbukti efektif untuk menangkap tren jangka panjang dan pola seasonal yang terjadi dalam proses penerimaan mahasiswa baru. *Artificial Neural Networks* (ANN) telah menunjukkan kemampuan superior dalam menangkap pola non-linear yang kompleks dalam data. *Artificial Neural Networks* mengungguli algoritma *machine learning* lainnya dalam metrik evaluasi seperti *recall* dan *F1 score*. Dalam konteks prediksi akademik, Blanco et al. (2016) mengusulkan *deep neural network* untuk memprediksi performa akademik dengan mencapai akurasi 78%, sedangkan Rincon-Flores et al. (2020) menggunakan beberapa model seperti *K-nearest neighbors* (KNN) dan *Random Forest* untuk mencapai akurasi 80%. Beberapa penelitian telah melakukan perbandingan langsung antara model ARIMA dan ANN dalam berbagai domain. Hasil empiris menunjukkan superioritas model *neural networks* dibandingkan model ARIMA, dan temuan ini lebih lanjut menyelesaikan serta mengklarifikasi opini kontradiktif yang dilaporkan dalam literatur mengenai superioritas *neural networks* dan model ARIMA [7].

Studi perbandingan model BP *artificial neural network* dan model ARIMA dalam prediksi insiden AIDS menunjukkan bahwa kedua model dapat digunakan untuk memprediksikan insiden bulanan HIV/AIDS, tetapi efek *fitting* dan *forecasting* dari model BP *neural network non-linear* lebih baik daripada model ARIMA linear tradisional. Temuan ini konsisten dengan karakteristik data yang memiliki pola non-linear yang kompleks [8].

Aplikasi *artificial intelligence* dalam pendidikan telah meningkat dalam beberapa tahun terakhir, namun masih memerlukan pemahaman konseptual dan metodologis yang lebih lanjut [9]. Penelitian terbaru menangani kesenjangan teknis dalam prediksi performa mahasiswa dengan fokus pada algoritma alternatif selain *artificial neural networks* (ANNs), menggunakan metodologi yang ketat seperti *repeated k-fold cross-validation* dan *hyperparameter optimization* [2].

2. Metode Penelitian

Pada penelitian ini menggunakan metodologi penelitian kuantitatif dengan pendekatan deskriptif analitis dan komparatif [10]. Penelitian berfokus pada pengembangan dan perbandingan model prediksi jumlah mahasiswa baru menggunakan metode ARIMA dan *Neural Network*. Studi ini menggunakan data *time series* historis jumlah mahasiswa baru selama periode 6 tahun terakhir (2019-2024) untuk membangun, melatih, dan mengevaluasi model prediksi.



Gambar 1. Kerangka penelitian.

2.1. Pengumpulan Data

Tahap ini melibatkan pengumpulan data historis jumlah mahasiswa baru dari periode-periode sebelumnya, yaitu dari tahun 2019 sampai dengan 2024. Data diperoleh dari bagian PMB Universitas Bumigora Mataram. pengumpulan data ini hanya bersumber dari data sekunder dengan teknik pengumpulan data studi dokumen, teknik studi dokumen tersebut yaitu adalah data mahasiswa yang didapatkan dari bagian Penerimaan Mahasiswa Baru Universitas Bumigora Mataram, dengan menggunakan surat resmi dari kampus sendiri tempat peneliti kuliah. Total keseluruhan data mahasiswa yang diminta dari tahun 2019 sampai 2024 berjumlah 5,229 data.

Tabel 1. Data mahasiswa.

Tahun	Bulan	Tgl Daful	Gelombang	Jurusan	Kab/Kota
2019	April	1/4/2019	1	Ilkom	LOTIM
2020	April	1/4/2020	2	DKV	LOTENG
2021	April	1/4/2021	1	TI	LOBAR
...
2024	Agustus	30/8/2024	2	SI	Mataram

2.2. Preprocessing Data

Preprocessing data adalah proses yang mengubah data mentah ke dalam bentuk yang lebih mudah dipahami. Dengan ini peneliti hanya akan memilih beberapa data yang dibutuhkan saja, yaitu melalui proses *cleaning* data dengan cara membuang data yang tidak dibutuhkan (*missing values*) dan melalui proses transformasi data dengan cara mengubah bentuk data, atribut data, maupun format data [11]. Tahapan *preprocessing* data mahasiswa sangat penting untuk memastikan data yang bersih dan siap pakai. Dengan melakukan data *cleaning*, *transformation*, *integration*, dan *reduction*, kita bisa meningkatkan kualitas data sebelum dianalisis lebih lanjut atau digunakan dalam model *machine learning* [12].

Tabel 2. Hasil *preprocessing* data.

Tahun	Bulan	Jumlah daful
2019	01	0
2019	02	0
2019	03	0
2019	04	32
2019	05	156
2019	06	188
2019	07	158
2019	08	142
2019	09	98
2019	10	0
2019	11	0
2019	12	0

Dalam model ARIMA (*AutoRegressive Integrated Moving Average*), data wajib stasioner agar model dapat memberikan prediksi yang akurat. Stasioneritas berarti bahwa statistik utama seperti *mean*, *varians*, dan autokorelasi tidak berubah seiring waktu. Jika data tidak stasioner, kita perlu melakukan transformasi seperti *differencing*, *log transform*, atau dekomposisi tren sebelum menerapkan ARIMA [13]. Dalam ANN (*Artificial Neural Network*), data yang digunakan sebagai input harus dalam skala yang sesuai agar model dapat belajar dengan lebih cepat dan stabil. Dua teknik yang umum digunakan adalah Normalisasi dan Standarisasi [5].

2.3. Pemodelan ARIMA

Pemodelan ARIMA merupakan metode statistik yang umum digunakan dalam analisis dan peramalan deret waktu. Metode ini terdiri dari tiga komponen utama, yaitu *AutoRegressive* (AR), *Integrated* (I), dan *Moving Average* (MA). Komponen AR memanfaatkan hubungan antara observasi saat ini dengan beberapa observasi sebelumnya, sementara komponen I berfungsi untuk mengubah data menjadi stasioner melalui proses diferensiasi [14]. Di sisi lain, komponen MA mempertimbangkan kesalahan prediksi dari model yang sebelumnya.

$$\phi_p(B)(1-B)^d Y_t = \theta_q(B)\epsilon_t \quad (1)$$

Keterangan:

- Y_t = Data aktual pada waktu ke-t
- B = Operator lag (misalnya $BY_t = Y_{t-1}$)
- d = Derajat diferensiasi (untuk menjadikan data stasioner)
- ϵ_t = Error putih (*white noise*)
- $\phi_p(B)$ = Polinomial *autoregressive* (AR) order p
- $\theta_q(B)$ = Polinomial *moving average* (MA) order q

Selanjutnya, pemilihan parameter p , d , dan q dilakukan dengan bantuan grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).

2.4. Pemodelan ANN

Pemodelan *neural network* adalah pendekatan canggih dalam kecerdasan buatan yang meniru cara kerja otak manusia untuk memproses informasi. Jaringan saraf terdiri dari lapisan-lapisan *neuron*, termasuk lapisan input, lapisan tersembunyi, dan lapisan output [15].

$$\hat{y} = f \sum_{n=0}^n w_j \cdot x_j + b \quad (2)$$

Keterangan:

- \hat{y} = Output prediksi (Jumlah mahasiswa baru)
- x_j = Input ke-J (misalnya jumlah mahasiswa bulan lalu)
- w_j = Bobot (*weight*) antara input ke-j dengan neuron
- b = bias
- f = fungsi aktivasi (misalnya ReLU, sigmoid, tanh)

Berikut ini adalah tahapan untuk pemodelan *artificial neural network*:

- a. Penentuan arsitektur NN yaitu menentukan jumlah *layer*, neuron, dan fungsi aktivasi.
- b. *Training* ANN yaitu melatih model dengan algoritma *backpropagation*.
- c. Validasi model NN yaitu menggunakan *cross-validation* untuk memastikan tidak terjadi *overfitting*.

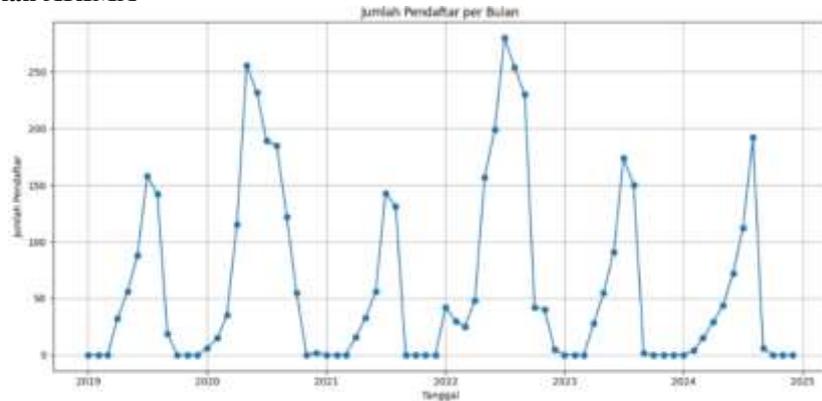
2.5. Evaluasi Model

Selanjutnya tahap mengevaluasi akurasi kedua model Arima dan *Neural Network* menggunakan metrik seperti, RMSE (*Root Mean Square Error*). RMSE (*Root Mean Square Error*) adalah metrik yang umum digunakan untuk mengukur tingkat akurasi dari prediksi suatu model dengan cara menghitung akar kuadrat dari rata-rata selisih kuadrat antara nilai prediksi dan nilai aktual. Kemudian MAE (*Mean Absolute Error*) adalah metrik yang digunakan untuk mengukur rata-rata nilai absolut dari selisih antara nilai prediksi dan nilai aktual. Selanjutnya MAPE (*Mean Absolute Percentage Error*) adalah metrik yang mengukur akurasi prediksi dalam bentuk persentase rata-rata dari kesalahan absolut.

3. Hasil dan Pembahasan

Penelitian ini bertujuan untuk mengevaluasi kinerja algoritma ARIMA dan ANN dalam melakukan prediksi jumlah mahasiswa baru Universitas Bumigora Mataram. Proses prediksi didahului oleh tahapan persiapan data yang meliputi pemodelan ARIMA (Uji Stasioner, estimasi parameter, hasil prediksi), pemodelan ANN (normalisasi data, pembagian data, hasil prediksi) evaluasi kinerja dan perbandingan kedua algoritma.

3.1. Pemodelan ARIMA



Gambar 2. Pola data tahunan.

Karena datanya tidak stasioner maka perlu dilakukan *differencing* agar menjadi stasioner dan dapat dimasukkan ke pemodelan arima maka perlu dilakukan uji stasioneritas.

3.1.1. Uji Stasioner

Berdasarkan visualisasi data awal menunjukkan bahwa data tidak stasioner maka diperlukan *differencing* $d = 1$ dengan melakukan uji stasioneritas menggunakan metode (*Kwiatkowski-Phillips-Schmidt-Shin Test*) adalah uji stasioner yang dikembangkan oleh Kwiatkowski, Phillips, Schmidt, dan Shin pada tahun 1992. Tes ini memiliki karakteristik yang berbeda dari ADF Tes. Hipotesis *KPSS Test* H_0 (Null Hypothesis): Data adalah stasioner H_1 (Alternative Hypothesis): Data adalah non-stasioner (memiliki unit root). KPSS tes dihitung dengan persamaan (3):

$$KPSS = (1/T^2) \times \Sigma(S_t^2) / \sigma^2 \tag{3}$$

Keterangan:

- T = jumlah observasi
- S_t = partial sum dari residual
- σ^2 = estimasi varians jangka panjang

KPSS Test:
 KPSS Statistic: 0.017243
 p-value: 0.100000
Critical Values:
 10%: 0.347
 5%: 0.463
 2.5%: 0.574
 1%: 0.739

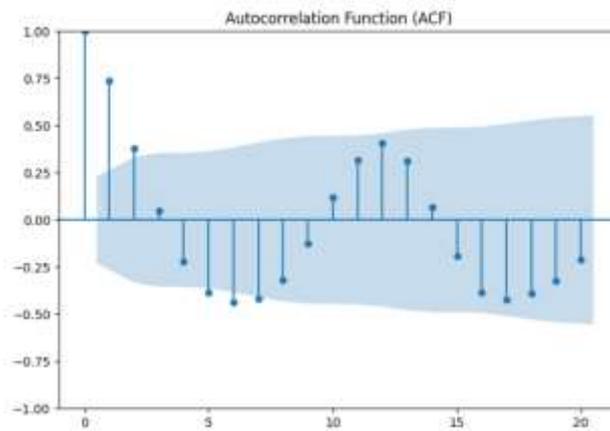
Data STASIONER (Fail to reject H_0)
KESIMPULAN: Data STASIONER
 Data menjadi stasioner dengan *differencing order* 1

Gambar 3. *Differencing* order KPSS

3.1.2. Parameter (p, d, q)

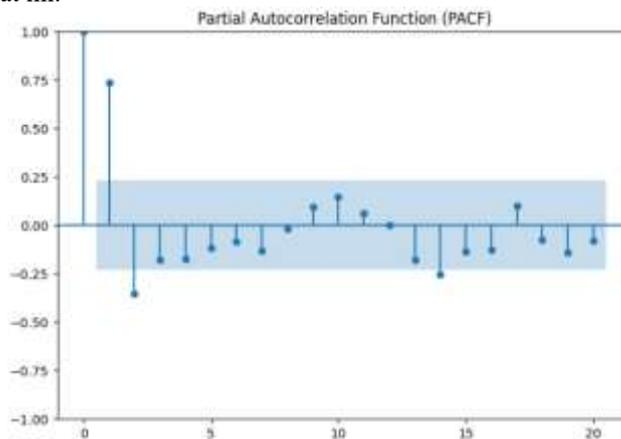
Tahap ini adalah untuk menentukan parameter ARIMA (p, d, q) terbaik, melatih model ARIMA dengan parameter tersebut dan mengevaluasi kinerjanya dengan metrik error. Untuk mengidentifikasi perlu

dilihat ACF *plot - cut-off* setelah lag p, pada gambar dibawah ini kita dapat mengidentifikasi bahwa nilai p adalah 1.



Gambar 4. *Plot ACF*

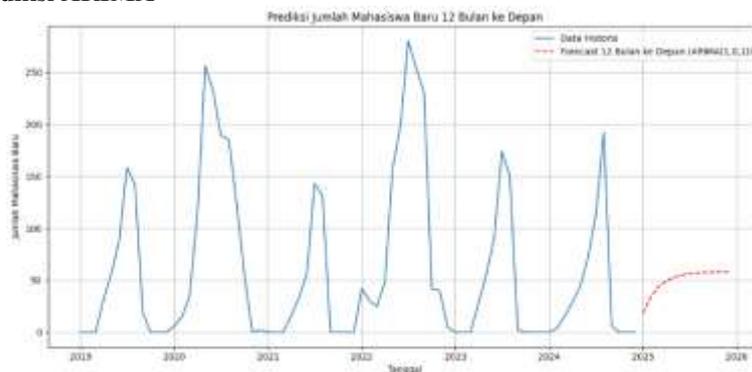
Selanjutnya nilai d sudah didapatkan dari hasil uji stasioner menggunakan metode ADF (*Augmented Dickey-Fuller Test*) dan KPPS (*Kwiatkowski-Phillips-Schmidt-Shin Test*). q (*Moving Average Order*) merupakan jumlah lag dari *error terms* yang digunakan, seberapa banyak *error* masa lalu yang mempengaruhi nilai saat ini.



Gambar 5. *Plot ACF*

Pada Gambar 5. diatas dapat ditentukan bahwa untuk nilai q adalah 1. Berdasarkan seluruh analisis diatas karena data sudah stasioner maka dapat disimpulkan bahwa untuk pemodelan arima dapat kita gunakan $p = 1, d = 0$ dan $q = 1$ untuk diterapkan dalam model prediksi menggunakan metode ARIMA.

3.1.3. Hasil Prediksi ARIMA



Gambar 6. Visualisasi prediksi

Visualisasi hasil prediksi menunjukkan dua bagian utama, Garis biru merepresentasikan data historis jumlah mahasiswa baru dari waktu ke waktu. garis merah putus-putus: menunjukkan hasil prediksi selama 12 bulan ke depan (forecast) yang dihasilkan oleh model ARIMA(1,0,1). Hasil ini menunjukkan bahwa ARIMA(1,0,1) mampu memberikan prediksi yang cukup baik untuk tren umum, khususnya dalam konteks jumlah mahasiswa baru yang cenderung mengalami pertumbuhan atau pola tetap dari waktu ke waktu. Berikut tabel hasil prediksi ARIMA untuk 9 bulan kedepan.

Tabel 3. Hasil prediksi

Tanggal	Jumlah
2025/01/1	22.56
2025/02/1	43.25
2025/03/1	54.98
2025/04/1	61.64
2025/05/1	65.42
2025/06/1	67.67
2025/07/1	68.78
2025/08/1	69.47
2025/09/1	70.42

3.2. Pemodelan ANN

Tahapan pemodelan menggunakan ANN adalah sebagai berikut:

3.2.1. Normalisasi Data

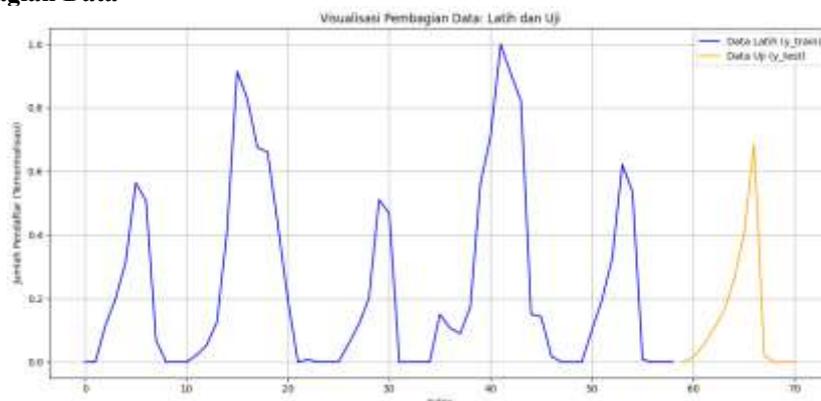
Pada tahap ini, dilakukan proses normalisasi terhadap data jumlah mahasiswa baru yang tersedia. Normalisasi bertujuan untuk mengubah skala nilai data agar berada dalam rentang yang seragam (biasanya 0 hingga 1).

Tabel 4. Normalisasi data

No	Tahun	Bulan	Jumlah Pendaftar	
1	2019	1	0	
2	2019	2	0	
3	2019	3	0	
4	2019	4	32	
5	2019	5	56	
count	72	72	72	72
mean	39	2021	6.5	61.27
std	23	1.719	3.476	78.95
min	1	2019	1	0
25%	19.75	2020	3.75	0
50%	39	2021	6.5	28.5
75%	58	2023	9.25	112.75
max	77	2024	12	280

Tabel 4. menunjukkan bahwa data telah berhasil dinormalisasi, sehingga siap digunakan dalam pemodelan seperti *Artificial Neural Network* (ANN) yang sensitif terhadap skala data.

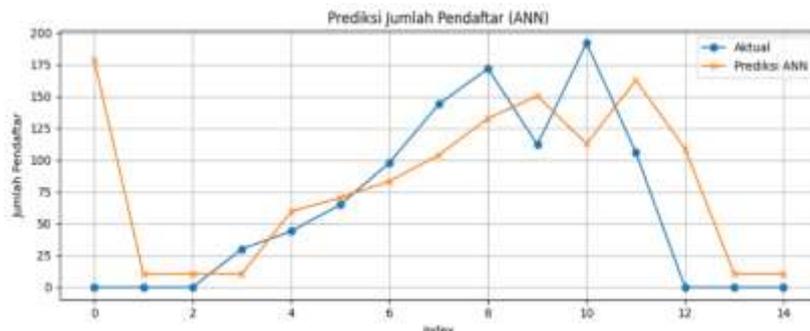
3.2.2. Pembagian Data



Gambar 7. Visualisasi pembagian data

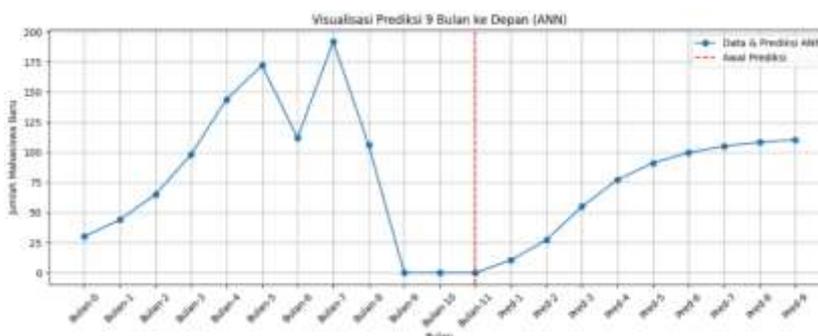
Garis oranye adalah data uji (*y_{test}*) digunakan untuk mengevaluasi akurasi prediksi, dengan memisahkan 1 tahun terakhir sebagai data uji, model dapat dievaluasi secara objektif terhadap data yang belum pernah dilihat sebelumnya.

3.2.3. Hasil Prediksi ANN



Gambar 8. Visualisasi prediksi ANN

Gambar 11. menunjukkan hasil prediksi menggunakan menggunakan model ANN mampu menangkap pola umum *tren* naik hingga puncaknya, meskipun nilainya tidak setinggi data aktual. Namun setelah puncak (bulan ke-11), model tidak mampu mengikuti penurunan drastis seperti pada data aktual. Sebaliknya, prediksi tetap menunjukkan pola naik dan kemudian datar. Pada awal periode (bulan 0–12), model cukup akurat karena jumlah data relatif stabil. pada pertengahan menjelang puncak model berhasil menangkap tren kenaikan, tetapi tidak seakurat data aktual yang naik sangat tajam. Setelah puncak di sinilah model mulai gagal memprediksi penurunan drastis yang terjadi di dunia nyata.



Gambar 8. Hasil prediksi ANN

3.3. Perbandingan Model

Tabel 5. Evaluasi model ARIMA dan ANN

Metrik Evaluasi	ARIMA	ANN
MAE	44.67	26.32
RMSE	53.26	47.47
MSE	2.836.18	2.253.52
MAPE	17.9%	11.65%

Berdasarkan Tabel 5. dapat disimpulkan bahwa model ANN lebih akurat dan stabil dibandingkan model ARIMA dalam memprediksi jumlah mahasiswa baru Universitas Bumigora Mataram. Ini karena model ANN mampu menangkap pola non-linear dalam data yang tidak mampu ditangkap oleh ARIMA, yang cenderung linier.

4. Penutup

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa tujuan utama penelitian, yaitu mengevaluasi performa model prediksi dalam memprediksi jumlah mahasiswa baru Universitas Bumigora MATARAM, telah tercapai dengan baik. Model *Artificial Neural Network* (ANN) menunjukkan performa yang lebih unggul dibandingkan dengan ARIMA, baik pada data asli maupun setelah dilakukan evaluasi berdasarkan metrik MAE, MSE, dan RMSE dengan persentasi MAPE sebesar

11,65% untuk algoritma ANN dan 17,9% untuk algoritma ARIMA. Hal ini menunjukkan bahwa pemilihan algoritma yang tepat sangat berpengaruh terhadap hasil prediksi. Secara umum, model ANN lebih disarankan untuk digunakan dalam memprediksi jumlah mahasiswa baru karena memberikan hasil yang lebih akurat dan sesuai dengan kompleksitas data historis yang digunakan. Penelitian ini menunjukkan bahwa metode prediksi yang berbasis kecerdasan buatan seperti ANN dapat menjadi alternatif yang lebih unggul dibandingkan metode statistik konvensional seperti ARIMA, khususnya dalam konteks data pendidikan.

Penelitian selanjutnya disarankan untuk dapat dikembangkan lebih lanjut menjadi sistem prediksi berbasis aplikasi atau dashboard interaktif yang dapat digunakan pihak universitas sebagai alat bantu pengambilan keputusan.

Daftar Pustaka

- [1] S. Maslamah, A. Nur Handayani, and G.-J. Horng, "Forecasting University Admissions through Student Achievement using Arima Method," *J. Educ. Technol.*, vol. 9, no. 1, pp. 10–20, 2025, [Online]. Available: <https://doi.org/10.23887/jet.v9i1.860>
- [2] F. A. Fitrony, L. D. Supraba, T. Rantung, I. M. A. Agastya, and K. Kusriani, "Analysis to Predict the Number of New Students At UNU Pasuruan using Arima Method," *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 14, no. 1, pp. 123–128, 2025, doi: 10.32736/sisfokom.v14i1.2251.
- [3] T. Fang-Mei, Y. Hsiao-Cheng, and T. Gwo-Hsiung, "Combining Neural Network Model with Seasonal Time Series ARIMA model," *Technol. Forecast. Soc. Change*, vol. 69, no. 2002, pp. 71–87, 2002.
- [4] "No Title," no. May, 2023.
- [5] F. E. James and J. L. Weese, "Neural Network-Based Forecasting of Student Enrollment With Exponential Smoothing Baseline and Performance Analysis," *ASEE Annu. Conf. Expo. Conf. Proc.*, 2022, doi: 10.18260/1-2--41751.
- [6] L. Wang, H. Zou, J. Su, L. Li, and S. Chaudhry, "An ARIMA-ANN Hybrid Model for Time Series Forecasting," *Syst. Res. Behav. Sci.*, vol. 30, no. 3, pp. 244–259, 2013, doi: 10.1002/sres.2179.
- [7] A. Aslanargun, M. Mammadov, B. Yazici, and S. Yolacan, "Comparison of ARIMA, neural networks and hybrid models in time series: Tourist arrival forecasting," *J. Stat. Comput. Simul.*, vol. 77, no. 1, pp. 29–53, 2007, doi: 10.1080/10629360600564874.
- [8] T. W. Mapuwei, J. Ndava, M. Kachaka, and B. Kusotera, "An Application of Time Series ARIMA Forecasting Model for Predicting Tobacco Production in Zimbabwe," *Am. J. Model. Optim.*, vol. 9, no. 1, pp. 15–22, 2022, doi: 10.12691/ajmo-9-1-3.
- [9] M. Valipour, M. E. Banihabib, and S. M. R. Behbahani, "Monthly inflow forecasting using autoregressive artificial neural network," *J. Appl. Sci.*, vol. 12, no. 20, pp. 2139–2147, 2012, doi: 10.3923/jas.2012.2139.2147.
- [10] N. Marisetty, "Forecasting of Selected International Stock Indices Returns By Using Arima Model," vol. 14, pp. 66083–66091, 2024, [Online]. Available: <https://doi.org/10.37118/ijdr.28098.07.2024>
- [11] A. A. Adebiyi, A. O. Adewumi, and C. K. Ayo, "Comparison of ARIMA and artificial neural networks models for stock price prediction," *J. Appl. Math.*, vol. 2014, pp. 9–11, 2014, doi: 10.1155/2014/614342.
- [12] H. Bousnguar, L. Najdi, and A. Battou, "Forecasting approaches in a higher education setting," *Educ. Inf. Technol.*, vol. 27, no. 2, pp. 1993–2011, 2022, doi: 10.1007/s10639-021-10684-z.
- [13] J. S. Armstrong and F. Collopy, "Error measures for generalizing about forecasting methods: Empirical comparisons," *Int. J. Forecast.*, vol. 8, no. 1, pp. 69–80, 1992, doi: 10.1016/0169-2070(92)90008-W.
- [14] "1994. Time Series Analysis-Forecasting and Control.pdf."
- [15] E. Okewu, P. Adewole, S. Misra, and R. Maskeliunas, "Artificial Neural Networks for Educational Data Mining in Higher Education : A Systematic Literature Review Artificial Neural Networks for Educational Data Mining in Higher Education : A Systematic Literature Review," *Appl. Artif. Intell.*, vol. 35, no. 13, pp. 983–1021, 2021, doi: 10.1080/08839514.2021.1922847.