

PENERAPAN METODE *FORECASTING* PADA JUMLAH SISWA BARU DI SEKOLAH DASAR BERBASIS DATA HISTORIS MENGGUNAKAN ARIMA, LSTM, DAN GRU

Nandi Dwi Husni Sadikin, Ignatius Wiseto Prasetyo Agung

Teknik Informatika, Universitas Adhirajasa Reswara Sanjaya

Jl. Sekolah Internasional No.1-2, Antapani, Kota Bandung, Jawa Barat, Indonesia

nandwhs03@gmail.com

ABSTRAK

Peramalan jumlah siswa baru merupakan elemen penting dalam perencanaan pendidikan, karena membantu sekolah dalam menyusun strategi pengelolaan sumber daya yang efektif. Namun, proses ini sering terkendala oleh fluktuasi data historis dan pemilihan metode peramalan yang kurang tepat. Penelitian ini bertujuan membandingkan kinerja tiga model peramalan deret waktu ARIMA, LSTM, dan GRU dalam memprediksi jumlah siswa baru berdasarkan data historis dari SDN Pasawahan 09. Model ARIMA dipilih sebagai perwakilan metode statistik klasik, sementara LSTM dan GRU mewakili model deep learning yang mampu menangani data sekuensial dan ketergantungan jangka panjang. Proses penelitian mencakup preprocessing data, pembagian data latih dan uji (80:20), serta evaluasi kinerja menggunakan tiga metrik utama: RMSE, MAE, dan MAPE. Hasil evaluasi menunjukkan bahwa ARIMA memiliki performa terbaik dengan RMSE sebesar 3.54, MAE 2.56, dan MAPE 7.73%. LSTM dan GRU masing-masing mencatat RMSE 7.63 dan 6.54; MAE 7.24 dan 6.05; serta MAPE 22.37% dan 18.82%. Selain lebih akurat, ARIMA juga menunjukkan efisiensi waktu pelatihan yang lebih tinggi dibanding dua model lainnya.

Kata kunci : *Forecasting, Time Series, ARIMA, LSTM, GRU*

1. PENDAHULUAN

Pendidikan merupakan aspek fundamental dalam pembangunan negara, di mana sekolah bertanggung jawab mencetak lulusan kompeten dan berkarakter adaptif terhadap perubahan zaman [1]. Khususnya pada pendidikan dasar, jumlah siswa baru setiap tahun menjadi indikator vital untuk perencanaan tenaga pengajar, fasilitas, dan alokasi anggaran sekolah, sehingga pengelolaan pendidikan yang komprehensif dan responsif menjadi sangat penting [2].

Pengelolaan pendidikan, sebagai standar nasional berdasarkan Undang-Undang Nomor 20 Tahun 2003, mencakup perencanaan, pelaksanaan, dan pengawasan kegiatan pendidikan untuk mencapai efisiensi dan efektivitas. Standar ini mendorong sekolah untuk merencanakan penerimaan siswa baru dengan lebih baik guna menghindari kekurangan atau kelebihan kapasitas yang dapat mempengaruhi kualitas pembelajaran [3]. Meskipun demikian, ketidakpastian jumlah pendaftar setiap tahunnya tetap menjadi tantangan utama bagi sekolah dalam menyusun strategi yang efektif.

Dalam beberapa tahun terakhir, kemajuan teknologi dan teknik analisis data telah membuka peluang baru untuk memecahkan berbagai masalah, termasuk di sektor pendidikan. Metode peramalan (*forecasting*) menjadi salah satu pendekatan yang dapat dimanfaatkan, memungkinkan prediksi lebih tepat melalui analisis pola data historis. Pendekatan ini berpotensi menjadi solusi strategis untuk mendukung perencanaan pendidikan yang lebih efisien dan terarah [4].

Penelitian ini diharapkan dapat memberikan beberapa manfaat yang signifikan bagi berbagai pihak.

Bagi SDN Pasawahan 09, hasil penelitian ini akan menyediakan sistem peramalan jumlah siswa baru yang lebih akurat, sehingga mempermudah proses perencanaan strategis terkait alokasi tenaga pengajar, fasilitas kelas, penyusunan anggaran, dan pengelolaan kapasitas sekolah secara keseluruhan. Hal ini dapat meningkatkan efisiensi operasional dan kualitas pelayanan pendidikan. Bagi pengembangan ilmu pengetahuan, penelitian ini berkontribusi dalam memperkaya literatur mengenai aplikasi metode *forecasting* berbasis *machine learning* (khususnya LSTM dan GRU) dan statistik tradisional (ARIMA) pada data *time series* di sektor pendidikan, serta memberikan perbandingan empiris yang relevan mengenai kinerja dan efisiensi komputasi antar model.

Penelitian ini berfokus pada penerapan metode *forecasting* untuk memprediksi jumlah siswa baru di SDN Pasawahan 09. Data yang digunakan adalah data historis jumlah siswa baru dari tahun 2004 hingga 2024. Model *forecasting* yang akan diterapkan dan dibandingkan meliputi ARIMA, LSTM, dan GRU. Evaluasi kinerja model akan didasarkan pada metrik akurasi RMSE, MAE, dan MAPE, serta durasi waktu *training* sebagai indikator efisiensi komputasi. Prediksi yang dihasilkan akan berfokus pada peramalan jumlah siswa baru untuk 5 tahun ke depan.

2. TINJAUAN PUSTAKA

2.1. *Time Series Forecasting*

Time series, atau deret waktu, adalah kumpulan data observasi yang memiliki urutan pengamatan berorientasi waktu atau kronologis pada variabel yang diminati. Deret waktu terkait dengan pengukuran data yang dilakukan pada banyak titik waktu, membentuk

pola berdasarkan frekuensi tetap yang muncul secara berkala [5].

Data *time series* umumnya digunakan untuk mengidentifikasi pola tren dan volatilitas, serta menganalisis hubungan antar variabel yang berfluktuasi seiring waktu. Pemahaman pola dan hubungan ini menjadi dasar untuk peramalan (*forecasting*) atau evaluasi efektivitas kebijakan [6].

Time series forecasting adalah proses peramalan atau prediksi kejadian di masa depan yang didasarkan pada kejadian di masa lalu, menggunakan data historis yang bersifat deret waktu [7].

2.2. Arima

Model ARIMA adalah gabungan dari tiga komponen, yaitu *AutoRegressive* (AR), *Moving Average* (MA), dan *differencing* yang merepresentasikan elemen *Integrated* dalam namanya. Model ini termasuk dalam kategori model *regresi linier* yang berupaya memanfaatkan data historis dari variabel target untuk memperkirakan nilai di masa mendatang [8].

Notasi dasar yang digunakan model ARIMA yaitu ARIMA (p, d, q) dimana ordo (p,d,q) nantinya diganti dengan nilai integer. Berikut merupakan definisi dari masing-masing ordo ARIMA [9]:

- a. p menunjukkan jumlah lag observasi yang digunakan dalam model.
- b. d menunjukkan berapa kali data harus di-differencing agar menjadi stasioner.
- c. q mengacu pada jumlah komponen moving average yang disertakan dalam model.

2.3. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah jenis arsitektur *Recurrent Neural Network* (RNN) yang pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber. Dirancang untuk mengatasi masalah *exploding gradient* dan *vanishing gradient* yang sering terjadi pada RNN konvensional, terutama saat memproses data dengan ketergantungan jangka panjang. Oleh karena itu, LSTM sangat efektif untuk tugas prediksi atau klasifikasi data deret waktu [10].

Arsitektur LSTM mencakup tiga komponen utama: lapisan input, lapisan tersembunyi, dan lapisan output. Setiap blok dalam jaringan ini dilengkapi dengan sel memori dan tiga gerbang pengendali: *input gate*, *output gate*, dan *forget gate*. Komponen-komponen ini memungkinkan LSTM untuk menyimpan, menghapus, atau meneruskan informasi secara selektif, mendukung proses pembelajaran yang lebih efektif seiring waktu.

2.4. Gated Recurrent Unit (GRU)

Long Short-Term Memory (LSTM) memiliki varian, salah satunya Gated Recurrent Unit (GRU), diperkenalkan oleh Kyunghyun Cho. GRU memiliki arsitektur lebih sederhana dibandingkan LSTM, namun tetap akurat dan efektif mengatasi masalah *vanishing gradient* [11].

Berbeda dengan tiga gerbang pada LSTM, GRU hanya menggunakan dua gerbang dan tiga fungsi aktivasi. Hal ini mempercepat dan mengefisienkan komputasi, terutama untuk data besar, serta menjadikan GRU lebih sesuai untuk dataset berukuran kecil [12].

2.5. Penelitian Terdahulu

Penelitian sebelumnya digunakan sebagai acuan untuk penelitian ini. Nendi Sunendar, Harjono P. Putro, dan Rizki Hesanda [13] dalam studinya "Prediksi Penjualan Aerosol Menggunakan Algoritma ARIMA, LSTM dan GRU" membandingkan kinerja ARIMA (metode statistik tradisional) dengan LSTM dan GRU (*deep learning*) untuk memprediksi penjualan produk aerosol demi efisiensi perencanaan produksi. Mereka mengevaluasi model menggunakan metrik MSE, RMSE, MAE, dan MAPE. Hasilnya, LSTM menunjukkan prediksi terbaik dengan MAPE 10,76%, diikuti ARIMA (11,23%) dan GRU (11,47%). LSTM unggul dalam mengidentifikasi tren jangka panjang dan pola musiman, sementara GRU memiliki performa setara LSTM dengan keunggulan kecepatan pelatihan.

Selanjutnya, Abu Tholib, Nanda Kurnia, dan Fitwatul Khoiriyah [10] melakukan penelitian dengan judul "Prediksi Harga Emas Menggunakan Metode LSTM dan GRU" membandingkan kinerja LSTM dan GRU untuk memprediksi harga emas. Evaluasi mereka menunjukkan bahwa LSTM menghasilkan *error* lebih rendah berdasarkan MAE (0.0389), RMSE (0.0475), dan MAPE (5.2047%). Namun, GRU dinilai lebih efektif dan akurat dalam menangkap pola data, dengan model GRU terbaik mencapai MAE 0.0447, RMSE 0.0545, dan MAPE 6.0688%.


3. METODE PENELITIAN

Proses pengumpulan dan persiapan data dalam penelitian ini dilakukan dalam beberapa tahap. Pertama, data historis jumlah siswa baru SDN Pasawahan 09 dikumpulkan dari arsip administrasi sekolah yang tercatat secara manual dalam format buku induk nasional. Setelah data terkumpul, dilakukan proses *data cleaning* untuk memastikan kualitas data. Tahapan ini mencakup pengecekan dan penanganan nilai yang hilang (*missing values*) untuk memastikan data yang digunakan dalam analisis tidak mengandung nilai ekstrem yang dapat memengaruhi hasil model secara signifikan. Selanjutnya, data melalui tahap normalisasi menggunakan metode *MinMaxScaler* untuk mengubah skala data ke rentang 0-1, yang sangat penting untuk stabilitas dan kinerja model *deep learning* seperti LSTM dan GRU.

Tahapan analisis data dalam penelitian ini diawali dengan persiapan dataset untuk model *time series forecasting*. Data yang telah dinormalisasi kemudian dipecah menjadi data *training* dan data *testing* dengan rasio 80:20 untuk mengevaluasi kemampuan generalisasi model pada data yang belum pernah dilihat. Selanjutnya, implementasi model

forecasting dilakukan menggunakan algoritma ARIMA (Autoregressive Integrated Moving Average) sebagai metode statistik tradisional, serta LSTM (Long Short-Term Memory) dan GRU (Gated Recurrent Unit) sebagai metode *deep learning* berbasis *Recurrent Neural Network*. Masing-masing model dilatih menggunakan data *training* dan kemudian digunakan untuk memprediksi jumlah siswa baru pada data *testing*. Proses evaluasi kinerja model dilakukan berdasarkan akurasi prediksi menggunakan metrik Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE), yang disajikan dalam bentuk grafik dan tabel perbandingan.

Diagram alir (*flowchart*) tahapan penelitian untuk studi perbandingan akurasi algoritma ARIMA, LSTM, dan GRU dalam prediksi jumlah siswa baru di SDN Pasawahan 09 digambarkan pada Gambar 1 di bawah ini:



Gambar 1. Diagram Alir Penelitian

Penelitian ini menggunakan berbagai alat dan perangkat lunak untuk mendukung pengumpulan, analisis, dan penyajian data. Bahasa pemrograman Python digunakan sebagai bahasa utama, dengan

beberapa *library* pendukung seperti Pandas untuk manipulasi dan analisis data, serta Scikit-learn untuk preprocessing data dan perhitungan metrik evaluasi. Implementasi algoritma *deep learning* (LSTM dan GRU) dilakukan dengan menggunakan *framework* TensorFlow/Keras, sementara untuk model ARIMA diimplementasikan dengan *library* statsmodels. Matplotlib digunakan untuk menghasilkan visualisasi grafik yang informatif dan mudah dipahami, termasuk grafik perbandingan nilai aktual dan prediksi serta perbandingan metrik evaluasi antar model. Google Colab dimanfaatkan sebagai platform komputasi untuk menjalankan model yang membutuhkan sumber daya intensif.

4. HASIL DAN PEMBAHASAN

4.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data historis jumlah siswa baru SDN Pasawahan 09. Data ini diperoleh melalui proses ekstraksi dari arsip administrasi sekolah yang tercatat secara manual dalam format buku induk nasional. Sumber data utama berasal langsung dari catatan internal sekolah, yang memuat informasi jumlah siswa baru yang terdaftar setiap tahunnya. Proses pengumpulan data dilakukan untuk periode waktu dari tahun 2004 hingga 2024. Hasil pengumpulan data menunjukkan total sebanyak 21 titik data observasi, yang masing-masing merepresentasikan jumlah siswa baru pada tahun tertentu. Data ini mencakup informasi kuantitatif yang akan menjadi variabel target untuk peramalan.

Data yang telah diperoleh selanjutnya disimpan dalam bentuk file *Comma Separated Values* (CSV). Data ini berisi dua kolom utama, yaitu kolom tahun, yang merepresentasikan dimensi waktu dari observasi, dan kolom siswa, yang berisi jumlah siswa baru sebagai variabel target yang akan diprediksi. Format CSV dipilih untuk kemudahan akses dan kompatibilitas dengan berbagai perangkat lunak analisis data dan pemrograman yang digunakan dalam penelitian ini.

4.2. Preprocessing Data

Tahapan yang pertama dalam preprocessing data ialah tahap *Data Cleaning*. Pada tahap ini, langkah yang dilakukan adalah memeriksa adanya data yang hilang atau *missing value* dalam dataset. Hal ini penting dilakukan untuk memastikan bahwa seluruh data yang akan digunakan dalam proses analisis dan peramalan berada dalam kondisi lengkap dan tidak menimbulkan kesalahan saat pemodelan. Pengecekan dilakukan dengan menggunakan fungsi khusus yang dapat mengidentifikasi nilai kosong dalam setiap kolom pada dataset. Hasil pengecekan menunjukkan bahwa tidak ada *missing value* yang terdeteksi pada kolom tahun maupun siswa. Ini mengindikasikan bahwa dataset jumlah siswa baru yang digunakan adalah lengkap dan siap untuk tahap preprocessing

selanjutnya tanpa memerlukan penanganan nilai hilang.

Tahap berikutnya adalah melakukan normalisasi terhadap data. Setiap fitur dalam dataset memiliki rentang nilai yang bervariasi, yang menunjukkan bahwa skala antar fitur tidak seragam. Normalisasi diperlukan agar seluruh fitur memiliki skala yang seimbang, sehingga tidak ada fitur dengan nilai yang terlalu tinggi atau terlalu rendah dibandingkan yang lain. Untuk menghindari terjadinya bias atau anomali dalam proses pengolahan data, peneliti menerapkan metode normalisasi MinMax Scaler, di mana seluruh nilai pada dataset akan disesuaikan dalam rentang antara 0 hingga 1. Gambar 2 menunjukkan hasil sebelum dan sesudah normalisasi data

Sebelum		Sesudah	
tahun	siswa	tahun	siswa_normalized
2004-01-01	42	2004-01-01	0.433333
2005-01-01	40	2005-01-01	0.366667
2006-01-01	43	2006-01-01	0.466667
2007-01-01	45	2007-01-01	0.533333
2008-01-01	50	2008-01-01	0.700000

Gambar 2. Hasil Data Normalization

4.3. Pembagian Data Training dan Uji

Pembagian data dengan rasio 80:20 merupakan pendekatan yang lazim digunakan dalam pemodelan time series untuk memisahkan data menjadi dua kelompok, yakni data pelatihan (training data) dan data uji (testing data). Sebanyak 80% dari total data dimanfaatkan untuk melatih model agar dapat mengenali pola historis, sedangkan sisanya sebesar 20% digunakan untuk menguji kinerja model terhadap data yang belum pernah diolah sebelumnya. Tujuan dari pembagian ini adalah untuk menilai kemampuan model dalam memprediksi data baru yang mencerminkan kondisi nyata. Dalam penelitian ini, metode pembagian data 80:20 diterapkan sebagai langkah awal sebelum proses pemodelan dimulai.

4.4. Pelatihan Model ARIMA, LSTM, GRU

Pada tahap ini, model-model forecasting yang telah dipilih yaitu ARIMA (Autoregressive Integrated Moving Average), LSTM (Long Short-Term Memory), dan GRU (Gated Recurrent Unit) akan dilatih menggunakan data historis jumlah siswa baru yang telah melalui proses preprocessing. Masing-masing model memiliki karakteristik dan proses pelatihan yang spesifik untuk dapat mempelajari pola dan tren dari deret waktu. Model ARIMA, sebagai metode statistik klasik, berfokus pada dependensi linier data masa lalu, sedangkan LSTM dan GRU, sebagai arsitektur Recurrent Neural Network (deep learning), dirancang untuk menangkap dependensi jangka panjang dan pola non-linear yang kompleks, menjadikannya sangat efektif dalam menangani data deret waktu.

Proses pelatihan model diawali dengan persiapan dataset, yaitu pembagian data historis menjadi set data training dan testing. Data training digunakan untuk membangun dan mengoptimalkan parameter model, sementara data testing (data yang belum pernah dilihat model) akan digunakan untuk mengevaluasi kinerja peramalan model secara objektif.

Model ARIMA adalah pendekatan statistik yang kuat untuk peramalan deret waktu univariat. Proses pelatihan model ARIMA melibatkan identifikasi order (p,d,q) yang optimal, di mana p adalah order AR (Autoregressive), d adalah order I (Integrated/diferensiasi), dan q adalah order MA (Moving Average). Identifikasi order ini dapat dilakukan melalui analisis fungsi Autokorelasi (ACF) dan Parsial Autokorelasi (PACF), atau secara otomatis menggunakan fungsi `auto_arima()` dari library `pmdarima` yang membantu memilih parameter optimal berdasarkan kriteria informasi seperti AIC atau BIC. Dalam penelitian ini, implementasi model ARIMA yang digunakan merupakan model ARIMA manual, di mana parameter model yaitu (p,d,q) ditentukan secara eksplisit oleh penulis dengan nilai parameter yang digunakan adalah ARIMA(1,1,1). Setelah order ditentukan, model diinisialisasi menggunakan kelas ARIMA dari library `statsmodels` dan dilatih dengan data training melalui pemanggilan fungsi `fit()`. Model yang telah dilatih kemudian siap digunakan untuk melakukan prediksi pada data testing.

Model Long Short-Term Memory (LSTM) merupakan salah satu jenis arsitektur Recurrent Neural Network (RNN) yang dirancang khusus untuk mengatasi masalah vanishing gradient dan exploding gradient pada RNN konvensional, menjadikannya sangat efektif dalam menangani data deret waktu dengan ketergantungan jangka panjang. Proses pelatihan LSTM diawali dengan reshaping data input agar sesuai dengan format yang dibutuhkan oleh jaringan (sampel, timesteps, fitur). Model LSTM dibangun menggunakan Sequential API dari framework TensorFlow/Keras. Arsitektur model ini terdiri dari lapisan LSTM dengan 100 unit neuron dan fungsi aktivasi tanh, diikuti oleh layer Dropout dengan rate 0.2 untuk mencegah overfitting, dan Dense layer sebagai output. Model dikompilasi dengan optimizer Adam dan fungsi loss Mean Squared Error (MSE), dengan learning rate 0.001. Proses pelatihan dilakukan dengan memanggil fungsi `fit()` pada data training, menggunakan 200 epoch dan batch size 2, serta dilengkapi dengan Early Stopping untuk menghentikan pelatihan jika loss pada training set tidak membaik setelah beberapa epoch.

Model Gated Recurrent Unit (GRU) adalah varian dari LSTM yang memiliki arsitektur lebih sederhana dengan jumlah gerbang (gates) yang lebih sedikit. Meskipun strukturnya lebih ringkas, GRU tetap mampu memberikan tingkat akurasi yang sebanding dan efektif dalam mengatasi masalah vanishing gradient, serta menawarkan keunggulan dalam kecepatan komputasi. Proses pelatihan GRU

mirip dengan LSTM; data input di-reshape ke format yang sesuai, dan model dibangun secara sekuensial dengan layer GRU, Dropout, dan Dense layer. Arsitektur model GRU ini terdiri dari dua layer GRU, di mana layer pertama memiliki 150 unit neuron dengan fungsi aktivasi tanh dan `return_sequences=True`, diikuti oleh layer Dropout dengan rate 0.3. Layer GRU kedua memiliki 75 unit neuron dengan fungsi aktivasi tanh, diikuti oleh layer Dropout dengan rate 0.3, dan diakhiri dengan Dense layer sebagai output. Model dikompilasi dengan optimizer Adam dan fungsi loss MSE, dengan learning rate 0.001. Pelatihan dilakukan dengan fungsi `fit()` pada data training menggunakan 200 epoch dan batch size 2, dengan Early Stopping sebagai callback untuk mengontrol proses pelatihan dan mencegah overfitting.

4.5. Evaluasi

Setelah prediksi dilakukan, hasil prediksi jumlah siswa baru yang dibuat menggunakan algoritma ARIMA, LSTM, dan GRU dievaluasi. Evaluasi ini dilakukan dengan metrik *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Hasilnya menunjukkan seberapa baik masing-masing model mampu memprediksi jumlah siswa baru mendekati nilai aktual.

Tabel 1. Matriks Evaluasi

Model	RMSE	MAE	MAPE
ARIMA	3.54	2.56	7.72%
LSTM	7.63	7.24	22.37%
GRU	6.54	6.05	18.82%

Evaluasi model dilakukan menggunakan beberapa metrik utama, yaitu RMSE, MAE, dan MAPE. RMSE mengukur akar kuadrat dari rata-rata kuadrat selisih antara nilai aktual dan prediksi, memberikan bobot lebih pada kesalahan besar. RMSE dapat dihitung menggunakan rumus:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (1)$$

MAE mengukur rata-rata dari selisih absolut antara nilai aktual dan prediksi, menunjukkan rata-rata magnitudo kesalahan. MAE dapat dihitung menggunakan rumus

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

Sementara itu, MAPE mengukur rata-rata kesalahan prediksi dalam bentuk persentase dari nilai aktual, sangat berguna untuk interpretasi relatif terhadap skala data.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100 \quad (3)$$

Untuk model ARIMA, didapatkan hasil RMSE sebesar 3.5388. Nilai ini menunjukkan bahwa rata-rata akar kuadrat dari selisih kuadrat antara nilai prediksi


dan aktual adalah sekitar 3.5388 unit. Angka ini merefleksikan seberapa baik model dalam meminimalkan kesalahan prediksi yang besar. Selanjutnya, nilai MAE untuk ARIMA adalah 2.5642, yang berarti rata-rata absolut kesalahan prediksi model adalah sekitar 2.5642 unit. MAE memberikan indikasi langsung mengenai besaran kesalahan rata-rata tanpa mempertimbangkan arahnya. Terakhir, MAPE ARIMA tercatat sebesar 7.727%, menunjukkan bahwa rata-rata kesalahan prediksi dalam bentuk persentase dari nilai aktual adalah sekitar 7.727%. Nilai MAPE di bawah 10% ini umumnya dianggap sebagai indikasi akurasi peramalan yang baik.

Pada model LSTM, hasil evaluasi menunjukkan nilai RMSE sebesar 7.6323. Angka ini mengindikasikan bahwa rata-rata kesalahan kuadrat model LSTM secara signifikan lebih tinggi dibandingkan ARIMA, menunjukkan model ini kurang efektif dalam menekan kesalahan besar. Nilai MAE yang didapatkan adalah 7.2390, yang berarti rata-rata kesalahan absolut prediksi LSTM adalah sekitar 7.2390 unit. Ini juga menunjukkan tingkat kesalahan rata-rata yang lebih tinggi. Sementara itu, MAPE LSTM tercatat sebesar 22.373%. Nilai persentase kesalahan yang relatif tinggi ini menunjukkan bahwa prediksi model LSTM memiliki penyimpangan yang cukup besar dari nilai aktual dalam konteks data ini.

Untuk model GRU, hasil evaluasi menunjukkan nilai RMSE sebesar 6.5380. Meskipun lebih rendah dari LSTM, nilai RMSE ini masih lebih tinggi dibandingkan ARIMA, menunjukkan model GRU kurang optimal dalam meminimalkan kesalahan besar. Nilai MAE yang diperoleh adalah 6.0532, yang berarti rata-rata absolut kesalahan prediksi model GRU adalah sekitar 6.0532 unit. Ini juga mengindikasikan tingkat kesalahan rata-rata yang lebih tinggi dibandingkan ARIMA. Terakhir, MAPE GRU tercatat sebesar 18.819%. Nilai persentase kesalahan ini menunjukkan bahwa prediksi model GRU memiliki tingkat akurasi yang lebih rendah dibandingkan ARIMA, meskipun sedikit lebih baik dari LSTM.

Hasil pengukuran durasi pemodelan menunjukkan performa komputasi yang beragam antar algoritma. Model ARIMA mencatat waktu training tercepat (0.097 detik), unggul signifikan dibandingkan LSTM (10.83 detik) dan GRU (7.82 detik). Dan GRU (7.82 detik) sendiri lebih efisien dibandingkan LSTM (10.83 detik), ini sejalan dengan penelitian [14] yang menyatakan bahwa GRU secara umum lebih efisien daripada LSTM karena arsitekturnya yang lebih sederhana dengan parameter lebih sedikit. Dalam hasil ini, GRU memang menunjukkan waktu training 28% lebih cepat dibanding LSTM (3.03 detik). Namun demikian, baik LSTM maupun GRU tetap membutuhkan waktu komputasi yang secara signifikan lebih lama dibanding ARIMA

Grafik perbandingan durasi proses pemodelan ditampilkan pada Gambar 3:



Gambar 3. Perbandingan Durasi Pemodelan


4.6. Visualisasi Hasil

Berikut adalah visualisasi hasil dari peramalan masing masing model ARIMA untuk 5 tahun kedepan.

Tabel 2. Hasil Prediksi Model ARIMA

No	Tahun	Prediksi Jumlah Siswa
1	2025	30.1
2	2026	29.6
3	2027	29.8
4	2028	29.7
5	2029	29.8

Berdasarkan model ARIMA yang diterapkan pada data historis jumlah siswa, diperoleh prediksi untuk 5 tahun ke depan (2025-2029) dengan fluktuasi yang relatif stabil di kisaran 29 hingga 30 siswa. Hasil ini menunjukkan tren yang cenderung stationary (tidak ada peningkatan atau penurunan signifikan), dengan sedikit variasi tahunan. Nilai prediksi tertinggi terjadi di tahun 2025 dengan 30 siswa, sedangkan terendah di tahun 2026 dengan 29 siswa.




Gambar 4. Hasil Prediksi ARIMA

Selanjutnya, berikut adalah visualisasi hasil dari peramalan masing masing model LSTM untuk 5 tahun kedepan:

Tabel 3. Hasil Prediksi Model LSTM

No	Tahun	Prediksi Jumlah Siswa
1	2025	38.8
2	2026	39.6
3	2027	40.7
4	2028	42.5
5	2029	43.2

Berdasarkan model LSTM yang diterapkan pada data historis jumlah siswa, diperoleh prediksi untuk 5 tahun ke depan (2025-2029) dengan fluktuasi yang relatif naik di kisaran 38 hingga 43 siswa. Hasil ini menunjukkan tren yang cenderung increased (terjadi peningkatan). Nilai prediksi tertinggi terjadi di tahun 2029 dengan 43 siswa, sedangkan terendah di tahun 2025 dengan 38 siswa.




Gambar 5. Hasil Prediksi LSTM

Dan yang terakhir, berikut adalah visualisasi hasil dari peramalan masing masing model GRU untuk 5 tahun kedepan:

Tabel 4. Hasil Prediksi Model GRU

No	Tahun	Prediksi Jumlah Siswa
1	2025	30.1
2	2026	29.6
3	2027	29.8
4	2028	29.7
5	2029	29.8

Berdasarkan model GRU yang diterapkan pada data historis jumlah siswa, diperoleh prediksi untuk 5 tahun ke depan (2025-2029) dengan fluktuasi yang relatif naik di kisaran 37 hingga 41 siswa. Hasil ini menunjukkan tren yang cenderung increased (terjadi peningkatan). Nilai prediksi tertinggi terjadi di tahun 2029 dengan 41 siswa, sedangkan terendah di tahun 2025 dengan 37 siswa.



Gambar 6. Hasil Prediksi GRU

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengimplementasikan model ARIMA, LSTM, dan GRU untuk peramalan jumlah siswa baru. Dari segi akurasi, ARIMA terbukti menjadi model paling optimal, secara konsisten

menunjukkan performa unggul pada seluruh metrik evaluasi. Model ARIMA mencatat nilai RMSE terendah (3.5388), MAE terendah (2.5642), dan MAPE terendah (7.727%). Nilai MAPE ARIMA yang di bawah 10% ini, merujuk pada Target MAPE Lewis (1982), dianggap sebagai indikasi akurasi peramalan yang sangat akurat. Selain akurasi, ARIMA juga unggul signifikan dalam efisiensi komputasi, mencatat waktu training tercepat yaitu 0.097 detik, jauh lebih cepat dibandingkan LSTM (10.828 detik) dan GRU (7.824 detik). Keunggulan ganda ini menjadikan ARIMA pilihan terbaik untuk data *time series* dalam penelitian ini.

Untuk penelitian selanjutnya, disarankan beberapa pengembangan untuk meningkatkan kualitas dan generalisasi model. Pertama, perluasan dataset sangat dianjurkan, baik dari segi rentang waktu maupun penambahan fitur eksternal yang relevan seperti jumlah guru atau faktor demografis. Kedua, optimasi *hyperparameter* model dapat ditingkatkan, terutama untuk LSTM dan GRU, melalui metode seperti *Grid Search* atau *Random Search*, sementara untuk ARIMA, penggunaan fungsi *auto_arima()* dapat membantu pemilihan parameter secara otomatis dan optimal. Terakhir, disarankan untuk menambahkan model perbandingan lain seperti Prophet atau XGBoost, untuk mendapatkan perspektif yang lebih luas mengenai performa berbagai metode *time series forecasting*.

DAFTAR PUSTAKA

- [1] A. Bari, H. Hermansyah, and R. Rosdiawan, "Pengembangan Kurikulum Perguruan Tinggi Berbasis Kompetensi: Tantangan dan Strategi Menghadapi Era Globalisasi," *J-CEKI: Jurnal Cendekia Ilmiah*, vol. 4, no. 3, pp. 37–42, 2025.
- [2] A. Prasetyaningrum and S. Marmoah, "Analisis SWOT manajemen peserta didik dalam penerimaan peserta didik baru di sekolah negeri," *Jurnal Basicedu*, vol. 6, no. 4, pp. 5598–5604, 2022.
- [3] M. Ulum, "Kebijakan standar nasional pendidikan," *Syaikhuna: Jurnal Pendidikan Dan Pranata Islam*, vol. 11, no. 1, pp. 105–116, 2020.
- [4] M. N. Ustadha and I. K. D. Nuryana, "A Demand Forecasting Model For Women's Sandals in the MSME Supply Chain Using the Linear Regression Algorithm: A Case Study of Ann-D'Mello Sandals," *Journal of Emerging Information System and Business Intelligence (JEISBI)*, vol. 5, no. 3, pp. 139–149, 2024.
- [5] W. McKinney, *Python for data analysis: Data wrangling with pandas, numpy, and jupyter*. "O'Reilly Media, Inc.," 2022.
- [6] K. U. Syaliman, L. Maysofa, and S. Sapriadi, "Implementasi forecasting pada penjualan inaura hair care dengan metode single exponential smoothing," *Jurnal Testing Dan Implementasi Sistem Informasi*, vol. 1, no. 2, pp. 82–91, 2023.
- [7] A. F. Jumoorthy, R. Thoplan, and J. Narsoo, "High frequency volatility forecasting: A new approach using a hybrid ANN-MC-GARCH model," *International Journal of Finance & Economics*, vol. 28, no. 4, pp. 4156–4175, 2023.
- [8] T. Yiu, "Understanding ARIMA (Time Series Modeling)," *Towards Data Science*. URL: <https://towardsdatascience.com/understandingarima-time-series-modelingd99cd11be3f8>, 2020.
- [9] P. T. Yamak, L. Yujian, and P. K. Gadosey, "A comparison between arima, lstm, and gru for time series forecasting," in *Proceedings of the 2019 2nd international conference on algorithms, computing and artificial intelligence*, 2019, pp. 49–55.
- [10] A. Tholib, N. K. Agusmawati, and F. Khoiriyah, "Prediksi Harga Emas Menggunakan Metode Lstm Dan Gru," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, 2023.
- [11] Y. Karyadi, "Prediksi Kualitas Udara Dengan Metoda LSTM, Bidirectional LSTM, dan GRU," *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, vol. 9, no. 1, pp. 671–684, 2022.
- [12] W. Hastomo, A. S. B. Karno, N. Kalbuana, E. Nisfiani, and L. ETP, "Optimasi deep learning untuk prediksi saham di masa pandemi covid-19," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 7, no. 2, pp. 133–140, 2021.
- [13] N. Sunendar, H. P. Putro, and R. Hesnanda, "Prediksi Penjualan Aerosol Menggunakan Algoritma ARIMA, LSTM Dan GRU," *INSOLOGI: Jurnal Sains dan Teknologi*, vol. 4, no. 1, pp. 113–126, 2025.
- [14] S. Abbaspour, F. Fotouhi, A. Sedaghatbaf, H. Fotouhi, M. Vahabi, and M. Linden, "A comparative analysis of hybrid deep learning models for human activity recognition," *Sensors*, vol. 20, no. 19, p. 5707, 2020.