

IMPLEMENTASI DEEP LEARNING BERBASIS RECURRENT NEURAL NETWORK (RNN) UNTUK MEMPREDIKSI KEMAMPUAN PEMECAHAN MASALAH MATEMATIS SISWA

The Implementation of Recurrent Neural Network (RNN)-Based Deep Learning for Predict Students' Mathematical Problem-Solving Ability

Samuel Juliardi Sinaga^{1*}, Sanggam Gultom¹, Rolan Manurung¹

¹ Universitas HKBP Nommensen

*samuel.sinaga@uhn.ac.id

Diterima: 14 November 2025; Direvisi: 01 Desember 2025; Dipublikasi: 05 Desember 2025



ABSTRACT

Mathematical problem-solving ability is a fundamental aspect that reflects not only students' cognitive skills but also their reasoning and analytical abilities. In Indonesia, this skill remains a major challenge as students tend to focus on procedural solutions but struggle when faced with more complex or unfamiliar problems. This condition highlights the need for an innovative approach to predict students' mathematical problem-solving ability, enabling the provision of appropriate stimuli and facilitating further observation of their development.

The rapid advancement of Artificial Intelligence (AI) in recent years has created great opportunities for analyzing learning behavior and predicting students' academic performance. One of the most effective approaches for studying sequential data, such as student grades, is Deep Learning with the Recurrent Neural Network (RNN) model, which can capture temporal relationships between variables and model learning patterns dynamically.

This study focuses on predicting the level of mathematical problem-solving ability of students at SMP Negeri 7 Percut using 179 mathematics scores from four semesters. The dataset is divided into 150 training data points and 29 testing data points. Using the RNN method with a Long Short-Term Memory (LSTM) architecture, the best performance was achieved at 150 epochs and a learning rate of 0.001, producing RMSE and MAE values of 0.00. These results indicate that the LSTM method is effective in predicting students' mathematical problem-solving ability.

Keywords: Deep Learning, LSTM, Mathematic, Problem-solving, Recurrent Neural Network

ABSTRAK

Kemampuan pemecahan masalah matematis merupakan aspek mendasar yang tidak hanya mencerminkan kemampuan kognitif, tetapi juga kemampuan penalaran dan analisis siswa. Di Indonesia, kemampuan ini masih menjadi tantangan karena siswa cenderung fokus pada penyelesaian

prosedural, namun mengalami kesulitan menghadapi masalah yang lebih kompleks atau konteks baru. Kondisi ini menunjukkan perlunya pendekatan inovatif untuk memprediksi kemampuan pemecahan masalah matematis siswa, sehingga dapat diberikan stimulus yang sesuai dan dilakukan observasi terhadap perkembangannya.

Perkembangan pesat Artificial Intelligence (AI) dalam beberapa tahun terakhir telah memberikan peluang besar dalam menganalisis perilaku belajar serta memprediksi kinerja akademik siswa. Salah satu pendekatan yang unggul untuk menganalisis data berurutan seperti nilai siswa adalah Deep Learning dengan model Recurrent Neural Network (RNN), karena kemampuannya menangkap hubungan temporal antar variabel dan memodelkan pola belajar secara dinamis.

Penelitian ini berfokus pada prediksi tingkat kemampuan pemecahan masalah matematis siswa SMP Negeri 7 Percut menggunakan 179 data nilai matematika dari empat semester. Data dibagi menjadi 150 data training dan 29 data uji. Dengan metode RNN berbasis Long Short-Term Memory (LSTM), hasil terbaik diperoleh pada epoch 150 dan learning rate 0,001, menghasilkan nilai RMSE dan MAE sebesar 0,00, menunjukkan bahwa LSTM efektif dalam memprediksi kemampuan pemecahan masalah matematis siswa.

Kata Kunci: Deep Learning, LSTM, Matematis, Pemecahan Masalah, Recurrent Neural Network

1. PENDAHULUAN

Kemampuan memecahkan masalah matematika adalah salah satu kemampuan dasar yang harus dikembangkan dalam proses belajar di sekolah (Belinda & Susilowaty, 2023). Kemampuan ini tidak hanya menggambarkan aspek kognitif, tetapi juga menunjukkan kemampuan siswa dalam berpikir kritis, berlogika, serta menganalisis sesuatu secara teratur (Rachmawati & Adirakasiwi, n.d.). Dengan perkembangan teknologi kecerdasan buatan, banyak penelitian telah mencoba menggunakan metode *machine learning* dan *deep learning* untuk memprediksi kemampuan akademik siswa (Al Kiramy et al., 2024)(Muhammad Haris Diponegoro et al., 2021). Namun, kebanyakan dari penelitian tersebut hanya melihat hubungan tetap antar variabel tanpa memperhatikan pola urutan dari data hasil belajar siswa yang berbentuk waktu. Penelitian terbaru mulai menggunakan Recurrent Neural Network (RNN) dan turunannya, seperti Long Short-Term Memory (LSTM), untuk menangani data yang berurutan di berbagai bidang, termasuk dalam menganalisis cara siswa belajar (Khadafi & Yusrianti, 2025).

Namun, berdasarkan tinjauan literatur yang dilakukan, belum ada penelitian yang secara spesifik menerapkan metode RNN berbasis LSTM untuk memprediksi kemampuan siswa dalam menyelesaikan masalah matematika, terutama menggunakan data nilai dari beberapa semester sebelumnya (Azhar et al., 2021). Penelitian sebelumnya yaitu menggunakan LSTM dalam melakukan prediksi umur Trafo berdasarkan atribut tanggal, IS, energi, unbalanced load, suhu, V, dan L didapatkan hasil bahwa algoritma *deep learning-LSTM* mempunyai kinerja lebih baik dibandingkan dengan algoritma lainnya dengan nilai RMSE 0,0004 (Ningrum et al., 2021). Selanjutnya penelitian sebelumnya menggunakan RNN untuk diimplementasikan pada aplikasi *speech to text online* didapatkan hasil bahwa metode ini dapat meningkatkan akurasi dan mempercepat pengenalan ucapan untuk diubah menjadi text (Lubis et al., 2024). Selanjutnya terdapat penelitian untuk menguji kinerja antara dua metode yaitu RNN dan LSTM, didapatkan hasil bahwa LSTM bekerja lebih baik dengan memiliki nilai MAE lebih rendah sebesar 0,087 dibandingkan dengan metode RNN mendapatkan nilai MAE sebesar 0,092 (Larasati et al., 2024).

Penelitian ini fokus pada penerapan metode pembelajaran mendalam (Deep Learning) berbasis RNN dengan pendekatan LSTM untuk memprediksi kemampuan siswa SMP Negeri 7 Percut dalam menyelesaikan masalah matematika. Data yang digunakan adalah nilai matematika siswa dari empat semester terakhir dengan total dataset training berjumlah 150 dan dataset pengujian berjumlah 27 data, dengan tujuan mengidentifikasi pola perkembangan kemampuan belajar yang bisa dijadikan dasar dalam mengklasifikasikan kemampuan menyelesaikan masalah. Penelitian ini secara khusus bertujuan untuk (1) membuat model prediksi kemampuan siswa dalam memecahkan masalah matematika dengan menggunakan teknik Deep Learning berbasis arsitektur LSTM, (2) menguji pengaruh perubahan parameter pelatihan seperti jumlah epoch dan tingkat learning rate terhadap hasil prediksi, serta (3) mengevaluasi kinerja model dengan menggunakan beberapa metrik yaitu Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan tingkat akurasi.

2. METODE PENELITIAN

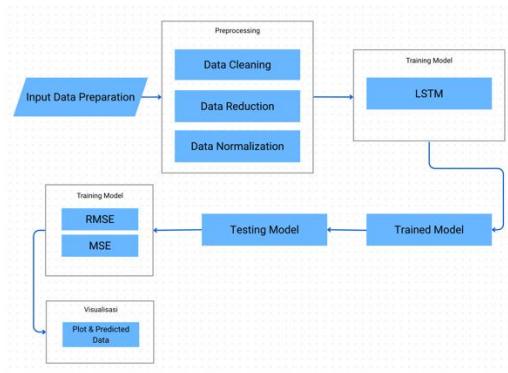
Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasional karena seluruh proses analisis dilakukan melalui pemodelan dan pengujian algoritma Deep Learning. Model yang digunakan adalah Recurrent Neural Network (RNN) berbasis Long Short-Term Memory (LSTM) untuk memprediksi kemampuan siswa dalam memecahkan masalah matematika berdasarkan data nilai matematika dari empat semester sebelumnya. Penelitian ini tidak melakukan manipulasi terhadap siswa, melainkan menggunakan data historis untuk membuat model prediktif yang bisa diuji secara objektif dengan menggunakan metrik evaluasi. Penelitian ini dilakukan di SMP Negeri 7 Percut, sebuah sekolah menengah pertama yang berada di Kecamatan Percut Sei Tuan, Kabupaten Deli Serdang. Sekolah ini secara umum mewakili kondisi akademik yang ada, sehingga dapat digunakan untuk menggambarkan perkembangan kemampuan matematika siswa di jenjang menengah pertama. Data yang digunakan dalam penelitian terdiri dari 179 siswa yang memiliki catatan nilai matematika selama empat semester berturut-turut. Arsitektur model yang digunakan dalam penelitian ini terdiri atas satu lapisan LSTM utama dengan jumlah unit sebanyak 64, diikuti oleh lapisan *dropout* sebesar 0,2 untuk mengurangi risiko overfitting. Setelah itu, model dilengkapi dengan satu lapisan *dense* berukuran 1 neuron sebagai keluaran. Proses pelatihan model menggunakan *optimizer* Adam, yang dipilih karena kemampuannya menyesuaikan laju pembelajaran secara adaptif sehingga stabil pada dataset berskala kecil. Model dirancang dengan tiga variasi *epoch*, yaitu 50, 150, dan 250, serta dua nilai *learning rate*, yaitu 0.001 dan 0.0001. Pemilihan kombinasi ini bertujuan mengevaluasi performa model pada berbagai tingkat kedalaman pelatihan serta sensitivitas terhadap perubahan parameter pembelajaran. Tujuan penelitian ini bukan fokus pada individu siswa secara langsung, melainkan pada catatan nilai matematika mereka yang digunakan sebagai data masukan dalam proses pembelajaran dan pengujian model.

Pembagian dataset dilakukan menggunakan metode train-test split dari total 179 data dengan proporsi 150 data pelatihan dan 29 data pengujian. Teknik ini dipilih mengingat ukuran dataset relatif kecil dan bersifat deret waktu, sehingga *k-fold cross validation* tidak digunakan karena dapat merusak urutan temporal data.

Namun, untuk memastikan model tidak bergantung sepenuhnya pada pola dalam data pelatihan, penelitian ini menambahkan proses validasi berupa:

1. Monitoring selisih loss antara train dan test selama pelatihan,
2. Evaluasi kurva learning untuk mengidentifikasi indikasi overfitting atau underfitting,
3. Visualisasi distribusi prediksi vs nilai aktual guna melihat pola kesalahan secara menyeluruh.

Agar lebih mudah dipahami, maka berikut ini adalah flowchart alur penelitian:



Gambar 1. Alur Penelitian

A. Data Preparation

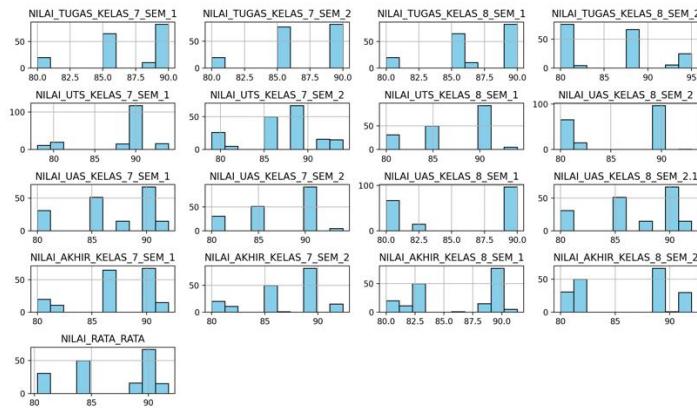
Data yang digunakan untuk penelitian ini bersumber dari nilai 179 siswa di SMP Negeri 7 Percut, data berisikan riwayat nilai siswa selama 2 tahun terakhir, nilai yang diambil meliputi nilai tugas, nilai mid semester, nilai akhir semester dan nilai yang diambil dari penyelesaian soal matematis sederhana (Harjo et al., n.d.).

B. Preprocessing Data

Sebelum melakukan proses LSTM, tentunya data melewati tahapan pembersihan data, data reduction dan data normalisasi. Berikut adalah rangkaian proses data yang digunakan;

1) Data Cleaning

Proses Pembersihan data sangat penting pada pembelajaran mesin karena dapat meningkatkan kinerja model (Selle et al., 2022). Data yang sudah bersih dapat digunakan untuk membantu memilih model pemebelajar mesin yang lebih sesuai dan mengurangi kesalahan yang mungkin terjadi akibat adanya data yang tidak tepat. Tujuan dari tahapan ini adalah memilih dan menghapus data yang dapat menurunkan keakuratan prediksi, sehingga mampu membuat dataset menjadi lebih rapi, bersih dan konsisten untuk dianalisis (Sakir, 2023). Hasil dari pembersihan data bisa dilihat pada gambar 2.



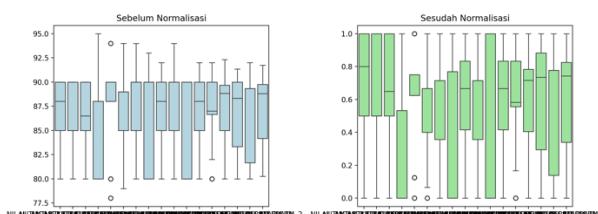
Gambar 2. Data Cleaning

2) Data Reduction

Proses ini diperlukan untuk menyederhanakan struktur data tanpa menghilangkan jumlah maupun informasi esensial yang dikandungnya. Penurunan atau penyederhanaan data dilakukan untuk menghasilkan himpunan data yang lebih efisien dan siap digunakan dalam proses pembelajaran, sehingga mampu mendukung peningkatan kinerja model secara keseluruhan. (Nurashila et al., 2023).

3) Data Normalization

Selain itu, proses normalisasi dilakukan untuk menyelaraskan skala nilai sehingga perbedaan rentang antar variabel—baik yang bernilai besar maupun kecil—tidak menimbulkan bias dalam pemodelan. Normalisasi umumnya diterapkan menggunakan metode Min-Max Scaling, yang memetakan seluruh nilai ke dalam interval 0 hingga 1. Tahapan ini krusial karena ketidaksesuaian skala data dapat memengaruhi kinerja dan stabilitas model. Dalam penelitian ini, normalisasi nilai Min-Max diimplementasikan dengan menggunakan *MinMaxScaler* dari pustaka Scikit-learn. (Kurniansyah et al., 2025). Berikut adalah gambar perbandingan sebelum dan sesudah normalisasi;

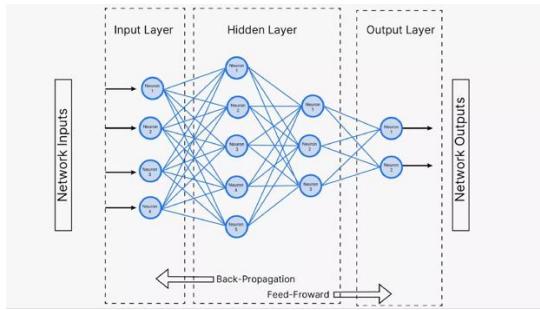


Gambar 3. Data Normalisasi

C. Model Training

Pada tahapan pelatihan ini, model dilatih untuk mengenali dan mempelajari pola yang terkandung dalam data yang tersedia, sehingga mampu menghasilkan prediksi yang tepat ketika diberikan data baru yang tidak pernah digunakan sebelumnya. Penelitian ini memanfaatkan pendekatan *deep learning* dengan menerapkan arsitektur LSTM sebagai

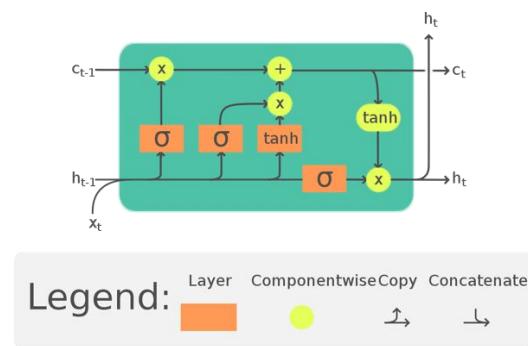
dasar pemodelannya. (Larasati et al., 2024). *Deep learning* merupakan pendekatan dalam *machine learning* yang memanfaatkan jaringan saraf tiruan dengan struktur berlapis atau terdiri dari lebih dari satu lapisan pemrosesan. (Nugroho & Nugroho, 2025). Tujuannya adalah untuk memberi pengajaran pada komputer agar mampu memahami serta melakukan pemodelan data yang kompleks melalui penggunaan susunan struktur jaringan saraf yang rumit. Teknik ini menggunakan beberapa lapisan, terutama lapisan masukan dan lapisan luaran, untuk membantu proses non-linier pada beberapa tahapan seperti pengelompokan pola dan pembelajaran fitur, seperti yang terlihat pada Gambar 4 yang menunjukkan susunan dari deep learning.



Source: analyticsvidhya.com (2025)

Gambar 4. Struktur Neural Networks

Struktur LSTM dibuat oleh Sepp Hochreiter bersama dengan Jürgen Schmidhuber pada tahun 1997 sebagai pengembangan dari jaringan saraf tiruan berulang (RNN). LSTM adalah jenis pemrosesan yang digunakan dalam RNN, dirancang khusus untuk mengatasi kesulitan dalam belajar dari data berurutan dalam jangka waktu yang lama (Cahyani et al., 2023). Keuntungan utama menggunakan LSTM adalah kemampuannya yang efektif dalam peramalan data berbentuk deret waktu serta kemampuannya dalam melakukan proses data yang tidak linier dalam volume besar dengan lebih efisien.



Source: medium.com (2025)

Gambar 5. Struktur LSTM

Gambar 4 menunjukkan struktur LSTM, yaitu jenis jaringan saraf berulang yang dirangkai untuk mengenang pola dalam data. Fungsi ini dicapai dengan cara memilih dan menyimpan

informasi tertentu serta melewatkannya menggunakan mekanisme gerbang di dalam setiap neuron. LSTM terdiri dari empat lapisan yang saling terhubung (Muhammad & Nurhaida, 2025). Gerbang-gerbang tersebut berfungsi mengendalikan bagaimana neuron mempertahankan maupun menghapus informasi tertentu. Pada arsitektur LSTM, terdapat unit khusus berupa blok memori yang ditempatkan pada lapisan tersembunyi berulang untuk mengelola aliran informasi tersebut.

D. Model Testing

Pada tahap ini dilakukan pengujian terhadap kinerja model dengan menggunakan data yang sama sekali tidak pernah dilibatkan selama proses pelatihan. Pengujian ini penting untuk menilai sejauh mana model mampu memprediksi kemampuan pemecahan masalah matematis siswa secara akurat pada data baru. Dalam proses pelatihan, *epoch* merepresentasikan satu siklus penuh pemrosesan seluruh data pelatihan, sedangkan *batch size* menunjukkan jumlah sampel yang diproses dalam satu langkah pembaruan bobot. Sementara itu, *callback* berfungsi sebagai mekanisme tambahan yang dijalankan selama pelatihan untuk melakukan tindakan tertentu, seperti menghentikan pelatihan ketika kondisi tertentu terpenuhi, menyesuaikan laju pembelajaran, atau menyimpan model dengan performa terbaik.

Lebih lanjut, tahap pengujian juga memerlukan evaluasi terhadap kemungkinan terjadinya *overfitting* atau *underfitting*. *Overfitting* muncul ketika model mempelajari pola pada data pelatihan secara berlebihan sehingga kinerjanya menurun pada data baru, sedangkan *underfitting* terjadi apabila model terlalu sederhana sehingga gagal mengenali pola utama dalam data pelatihan.

E. Model Evaluation

Setelah pelatihan model LSTM selesai, dilakukan tahap evaluasi untuk mengevaluasi kemampuan model. Dalam penelitian ini, beberapa parameter digunakan untuk menilai performa model yang telah dibuat. Parameter yang digunakan adalah untuk melihat pengaruh perubahan jumlah epoch terhadap tingkat loss pada model saat pelatihan dan pengujian, eksperimen dilakukan dengan menggunakan 50, 200, dan 250 epoch. Selain itu, dua tingkat learning rate yang berbeda, yaitu 0,001 dan 0,0001, juga diuji untuk mengetahui dampaknya terhadap hasil model. Berikut ini adalah rumus yang digunakan untuk melakukan evaluasi yaitu RMSE dan MSE;

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

Keterangan:

n = total pengamatan

y_i = nilai aktual ke i

\hat{y}_i = nilai prediksi ke i

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \gamma_i)^2$$

Keterangan:

- n = jumlah data
- y_i = nilai aktual ke i
- γ_i = nilai prediksi ke i
- $y_i - \gamma_i$ = kuadrat selisih antara nilai aktual dan prediksi

F. Data Visualization

Visualisasi pertama menggunakan grafik garis untuk menampilkan pola nilai matematika siswa dari empat semester sebelumnya. Grafik ini dibuat dari data yang sudah diproses sebelumnya dan berfungsi memastikan pola data tetap konsisten sebelum digunakan dalam pelatihan model. Grafik garis digunakan untuk melihat sejauh mana pola prediksi sesuai dengan data sebenarnya. Visualisasi ini menjadi indikator utama kesuksesan model dalam mempelajari pola nilai matematika siswa secara historis.

3. HASIL DAN PEMBAHASAN

Hasil dari penelitian ini memiliki variasi yang cukup terbatas dikarenakan data nilai matematika siswa pada empat semester sebelumnya memiliki rentang 80 – 100 dan fluktuasi tergolong stabil, oleh karena pola yang didapatkan dari data tidak terlalu tajam (ekstrem) maka nilai error akan terlihat sangat kecil. Temuan ini sesuai dengan ciri khas data deret waktu yang bersifat monoton dan tidak mengalami perubahan yang berarti. Hasil prediksi ini memberikan manfaat pedagogis yang penting. Model ini membantu guru mendeteksi sejak dini siswa yang berpotensi mengalami kesulitan, sehingga intervensi dapat diberikan secara lebih cepat dan terarah. Informasi prediktif tersebut memungkinkan guru menyesuaikan strategi pembelajaran, seperti memberikan latihan remedial, menguatkan konsep dasar, atau menerapkan pendekatan diferensiasi sesuai kebutuhan tiap siswa. Selain mendukung pemantauan perkembangan kemampuan dari waktu ke waktu, hasil prediksi juga dapat menjadi dasar bagi sekolah untuk merumuskan kebijakan pembelajaran yang lebih adaptif dan berbasis data.

A. Dataset

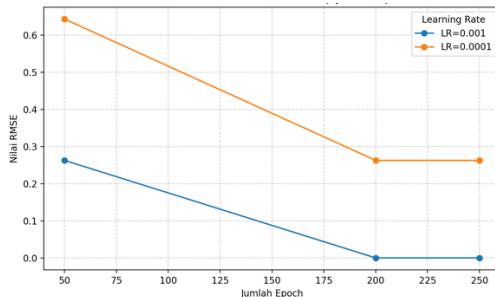
Pelatihan model dilakukan dengan tiga kali epoch, yaitu 50, 200, dan 250 kali, menggunakan learning rate sebesar 0.001 dan 0.0001 seperti yang ditentukan dalam kode Python. Berikut ini adalah tabel dataset yang akan digunakan dalam proses RNN-LSTM;

Tabel 1. Dataset Nilai Siswa

No	Nama	NIM	Kelas	NA
1	Abdul Aziz	128506089	Kelas 8-1	80,25
2	Afia	3127835447	Kelas 8-1	89,75
3	Afrilia Salsa Nabila Br Ginting	126717484	Kelas 8-1	89,75
4	Alwi Maulana	115825088	Kelas 8-1	88,79

5	Ananda Safitri	3122674957	Kelas 8-1	89,75
...

Nilai loss pada setiap tahap pelatihan dicatat menggunakan objek `history.history['loss']`, kemudian digambar dalam bentuk grafik seperti yang terlihat pada Gambar 6.

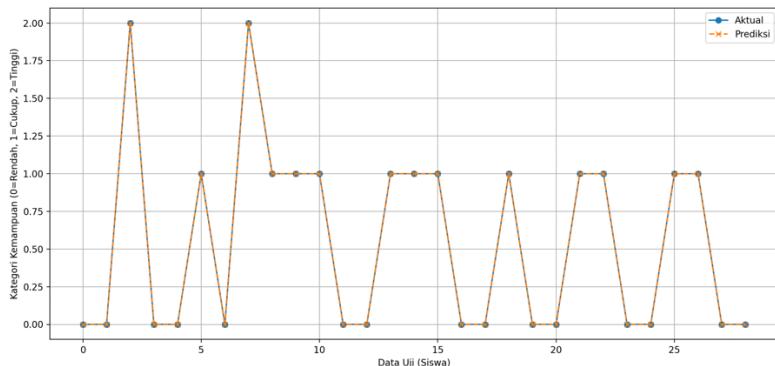


Gambar 6. Grafik Pergerakan Training Loss Selama Pelatihan

Grafik menunjukkan bahwa nilai loss terus berkurang selama semua tahap pelatihan, menandakan bahwa model mampu memahami pola dari data. Tidak ada tanda-tanda overfitting, karena perubahan pada loss validasi relatif sesuai dengan arah perubahan loss pelatihan.

B. Test Result

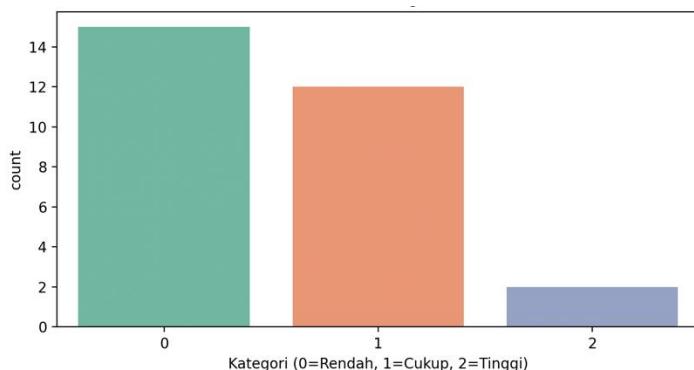
Setelah pelatihan, model diuji menggunakan 29 data yang telah dipisahkan sebagai dataset uji (`x_test`). Prediksi model dibandingkan secara langsung dengan nilai aktual dan divisualisasikan dalam *line plot* pada gambar berikut ini:



Gambar 7. Prediksi Model

Gambar tersebut menunjukkan bahwa kurva prediksi hampir seluruhnya berimpit dengan kurva hasil aktual. Hal ini sesuai dengan hasil dari model, yaitu nilai Mean Squared Error (MSE) dan Root Mean Squared Error (RMSE) yang mendekati 0,0000. Rendahnya nilai error ini merupakan konsekuensi dari karakteristik data yang homogen dan tidak banyak mengalami perubahan signifikan antarsemester. Untuk mendapatkan distribusi hasil dari 29 dataset testing diperlukan script berikut:

```
sns.countplot(x=y_pred_final, palette='Set2')
```



Gambar 8. Distribusi Prediksi Kemampuan Pemecahan Masalah dengan Dataset Testing

4. SIMPULAN

Penelitian ini menunjukkan bahwa model jaringan saraf tiruan berbasis Long Short-Term Memory (LSTM) mampu memprediksi kemampuan siswa dalam menyelesaikan masalah matematika dengan tingkat akurasi yang tinggi. Dengan menggunakan empat nilai semester sebelumnya sebagai data berbentuk deret waktu, model ini berhasil mempelajari pola-pola yang relatif stabil dan menghasilkan kesalahan yang sangat kecil, seperti yang ditunjukkan oleh nilai Mean Squared Error (MSE) dan Root Mean Squared Error (RMSE) yang mendekati nol. Hasil ini membuktikan bahwa LSTM tetap efektif digunakan pada dataset yang memiliki variasi nilai rendah. Inovasi dalam penelitian ini terletak pada penerapan arsitektur LSTM untuk data nilai matematika yang bersifat low-variance serta penggabungan proses pengolahan data, pelatihan, visualisasi, dan evaluasi dalam satu alur kerja prediksi yang sederhana namun praktis untuk digunakan dalam lingkungan sekolah.

Parameter pelatihan yang digunakan, yaitu satu lapisan LSTM dengan 50 neuron, learning rate sebesar 0,001 dan 0,0001, serta jumlah epoch sebanyak 50, 150, dan 250, terbukti mampu menghasilkan performa yang optimal. Secara keseluruhan, penelitian ini menunjukkan bahwa LSTM dapat digunakan sebagai alat bantu prediktif untuk memantau perkembangan belajar siswa dan membantu guru dalam mengambil keputusan serta meningkatkan kualitas proses pembelajaran.

5. UCAPAN TERIMA KASIH

Terimakasih kepada Universitas HKBP Nommensen Medan yang memberikan kesempatan kepada tim penulis untuk menerbitkan penelitian ini agar dapat berkontribusi bagi keilmuan khususnya ilmu pendidikan matematika.

6. REKOMENDASI

Untuk penelitian selanjutnya dapat digunakan data yang mengalami perubahan yang signifikan yaitu data nilai siswa yang memiliki perubahan yang ekstrim hal ini diperlukan untuk melihat variasi dan cara kerja RNN-LSTM nantinya apakah tetap mampu memberikan RMSE dan MSE yang sangat kecil atau terdapat perubahan yang bervariasi.

7. DAFTAR PUSTAKA

- Al Kiramy, R., Permana, I., Marsal, A., Munzir, M. R., & Megawati, M. (2024). Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT. Hajar Aswad: Comparison of RNN and LSTM Algorithm Performance in Predicting the Number of Umrah Pilgrims at PT. Hajar Aswad. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(4), 1224–1234. <https://doi.org/10.57152/malcom.v4i4.1373>
- Azhar, E., Saputra, Y., & Nuriadin, I. (2021). EKSPLORASI KEMAMPUAN PEMECAHAN MASALAH MATEMATIS SISWA PADA MATERI PERBANDINGAN BERDASARKAN KEMAMPUAN MATEMATIKA. *AKSIOMA: Jurnal Program Studi Pendidikan Matematika*, 10(4), 2129. <https://doi.org/10.24127/ajpm.v10i4.3767>
- Belinda, H., & Susilowaty, N. (2023). ANALISIS KEMAMPUAN PEMECAHAN MASALAH MATEMATIS SISWA BERDASARKAN SELF EFFICACY. *JP2M (Jurnal Pendidikan dan Pembelajaran Matematika)*, 9(1), 125–135. <https://doi.org/10.29100/jp2m.v9i1.4018>
- Cahyani, J., Mujahidin, S., & Fiqar, T. P. (2023). Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional. *Jurnal Sistem dan Teknologi Informasi (JustIN)*, 11(2), 346. <https://doi.org/10.26418/justin.v11i2.57395>
- Harjo, R. S. D., Anugrah, R., & Darmawan, J. (n.d.). *Prediksi Coin Kripto Dengan Menggunakan Metode LSTM (Long Short-Term Memory)*.
- Khadafi, M., & Yusrianti, O. (2025). *Sistem Prediksi Kebutuhan Stock Obat Menggunakan Metode Long Short Term Memory (LSTM) Time Series Berbasis Deep Learning*.
- Kurniansyah, J., Gusti, S. K., Yanto, F., & Affandes, M. (2025). *Implementasi Model Long Short Term Memory (LSTM) dalam Prediksi Harga Saham*. 6(2).
- Larasati, L., Saadah, S., & Yunanto, P. E. (2024). Recurrent Neural Networks (RNN) and Long Short-Term Memory (LSTM) Methods to Forecast Daily Turnover at BM Motor Ngawi. *Indonesian Journal of Artificial Intelligence and Data Mining*, 7(1), 141. <https://doi.org/10.24014/ijaidm.v7i1.27643>
- Lubis, N., Siambaton, Mhd. Z., & Aulia, R. (2024). Implementasi Algoritma Deep Learning pada Aplikasi Speech to Text Online dengan Metode Recurrent Neural Network (RNN). *sudo Jurnal Teknik Informatika*, 3(3), 113–126. <https://doi.org/10.56211/sudo.v3i3.583>
- Muhammad Haris Diponegoro, Sri Suning Kusumawardani, & Indriana Hidayah. (2021). Tinjauan Pustaka Sistematis: Implementasi Metode Deep Learning pada Prediksi

- Kinerja Murid. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 10(2), 131–138. <https://doi.org/10.22146/jnteti.v10i2.1417>
- Muhammad, R., & Nurhaida, I. (2025). Penerapan LSTM Dalam Deep Learning Untuk Prediksi Harga Kopi Jangka Pendek Dan Jangka Panjang. *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 10(1), 554–564. <https://doi.org/10.29100/jipi.v10i1.5904>
- Ningrum, A. A., Syarif, I., Gunawan, A. I., Satriyanto, E., & Muchtar, R. (2021). Algoritma Deep Learning-LSTM untuk Memprediksi Umur Transformator. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 8(3), 539–548. <https://doi.org/10.25126/jtiik.2021834587>
- Nugroho, A. S., & Nugroho, K. (2025). Comparison of RNN and LSTM Algorithms Based on Fasttext Embeddings in Sentiment Analysis on the Merdeka Mengajar Platform. *Sinkron*, 9(1), 117–128. <https://doi.org/10.33395/sinkron.v9i1.14296>
- Nurashila, S. S., Hamami, F., & Kusumasari, T. F. (2023). PERBANDINGAN KINERJA ALGORITMA RECURRENT NEURAL NETWORK (RNN) DAN LONG SHORT-TERM MEMORY (LSTM): STUDI KASUS PREDIKSI KEMACETAN LALU LINTAS JARINGAN PT XYZ. *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 8(3), 864–877. <https://doi.org/10.29100/jipi.v8i3.3961>
- Rachmawati, A., & Adirakasiwi, A. G. (n.d.). *ANALISIS KEMAMPUAN PEMECAHAN MASALAH MATEMATIS SISWA SMA*.
- Sakir, R. K. A. (2023). Pengujian Long-Short Term Memory (LSTM) Pada Prediksi Trafik Lalu Lintas Menggunakan Multi Server. *Jurnal Teknologi Elekterika*, 20(1), 14. <https://doi.org/10.31963/elekterika.v20i1.4242>
- Selle, N., Yudistira, N., & Dewi, C. (2022). Perbandingan Prediksi Penggunaan Listrik dengan Menggunakan Metode Long Short Term Memory (LSTM) dan Recurrent Neural Network (RNN). *Jurnal Teknologi Informasi dan Ilmu Komputer*, 9(1), 155–162. <https://doi.org/10.25126/jtiik.2022915585>