

**Ranah Research**
Journal of Multidisciplinary Research and Development
082170743613 ranahresearch@gmail.com <https://jurnal.ranahresearch.com>

E-ISSN: 2655-0865



DOI: <https://doi.org/10.38035/rj.v8i5>
<https://creativecommons.org/licenses/by/4.0/>

Perbandingan Kinerja Model Transformer dan LSTM dalam Prediksi Tingkat Pemahaman Siswa terhadap Materi Pembelajaran Digital

Risma Sihotang¹, Muhammad Said Hasibuan²

¹Institut Informatika dan Bisnis Darmajaya, Lampung, Indonesia

²Institut Informatika dan Bisnis Darmajaya, Lampung, Indonesia

Corresponding Author: rismasihotang19@gmail.com

Abstract: *The rapid adoption of digital learning platforms has generated large volumes of student interaction data that can be utilized to predict students' comprehension levels and support timely educational interventions. This study aims to compare the performance of the Transformer and Long Short-Term Memory (LSTM) models in predicting students' comprehension of digital learning materials. A quantitative comparative experimental approach was employed using student activity data collected from a Learning Management System (LMS). Data preprocessing included cleaning, normalization, sequence generation, and feature selection using Particle Swarm Optimization (PSO) to identify the most relevant features before model training. Model performance was evaluated using Accuracy, Precision, Recall, and F1-Score on the same testing dataset. The results indicate that the Transformer model outperformed LSTM across all evaluation metrics, achieving an accuracy of 92.3% and an F1-Score of 92.0%, while LSTM achieved an accuracy of 88.5% and an F1-Score of 87.9%. These findings demonstrate that the self-attention mechanism enables the Transformer model to capture complex relationships among learning features more effectively than LSTM. Therefore, the Transformer model is recommended for developing adaptive learning systems capable of accurately predicting student comprehension and supporting early academic intervention.*

Keyword: *Transformer, Long Short-Term Memory (LSTM), Student Comprehension Prediction, Digital Learning, Deep Learning.*

Abstrak: Perkembangan pembelajaran digital menghasilkan data interaksi siswa dalam jumlah besar yang dapat dimanfaatkan untuk memprediksi tingkat pemahaman siswa serta mendukung intervensi pembelajaran secara lebih dini. Penelitian ini bertujuan membandingkan kinerja model Transformer dan Long Short-Term Memory (LSTM) dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital. Penelitian menggunakan pendekatan kuantitatif dengan metode eksperimen komparatif menggunakan dataset aktivitas siswa yang diperoleh dari Learning Management System (LMS). Tahapan penelitian meliputi pra-pemrosesan data, normalisasi, pembentukan data sekuens, serta seleksi fitur menggunakan Particle Swarm Optimization (PSO) untuk memperoleh fitur yang paling relevan sebelum proses pelatihan model. Evaluasi dilakukan menggunakan metrik

Accuracy, Precision, Recall, dan F1-Score pada dataset pengujian yang sama. Hasil penelitian menunjukkan bahwa model Transformer memiliki kinerja lebih baik dibandingkan LSTM, dengan nilai Accuracy sebesar 92,3% dan F1-Score sebesar 92,0%, sedangkan model LSTM memperoleh Accuracy sebesar 88,5% dan F1-Score sebesar 87,9%. Temuan ini menunjukkan bahwa model Transformer lebih efektif dalam menangkap hubungan kompleks antarfitur pembelajaran sehingga direkomendasikan untuk mendukung pengembangan sistem pembelajaran adaptif dalam mengidentifikasi tingkat pemahaman siswa secara lebih akurat

Kata Kunci: Transformer, Long Short-Term Memory (LSTM), Prediksi Pemahaman Siswa, Pembelajaran Digital, Pembelajaran Mendalam.

PENDAHULUAN

Di era pendidikan digital saat ini, pemahaman siswa terhadap materi pembelajaran menjadi kunci utama keberhasilan proses belajar mengajar. Teknologi pembelajaran digital, seperti platform e-learning dan aplikasi interaktif, telah merevolusi cara siswa mengakses pengetahuan. perkembangan teknologi informasi dan komunikasi telah membawa perubahan signifikan di berbagai sektor, termasuk transportasi (Zou dkk., 2025). Perkembangan Teknologi Informasi dan Komunikasi (TIK) merupakan salah satu faktor utama yang mendorong transformasi pendidikan di era digital. Secara global, integrasi TIK dalam pendidikan dipandang sebagai strategi penting untuk meningkatkan mutu pembelajaran, memperluas akses terhadap sumber belajar, serta mengembangkan keterampilan abad ke-21, seperti kreativitas, kolaborasi, dan kemampuan pemecahan masalah (Picture, t.t.). Pembelajaran digital memberikan fleksibilitas kepada siswa dalam mengakses materi kapan saja dan di mana saja, namun di sisi lain menimbulkan tantangan bagi guru dalam memantau tingkat pemahaman siswa secara akurat (Ley dkk., 2023). Penilaian yang hanya mengandalkan hasil tes atau tugas sering kali belum mampu menggambarkan kondisi pemahaman siswa secara menyeluruh (Kaliisa dkk., 2023).

Namun, tantangan besar muncul dalam memprediksi tingkat pemahaman siswa secara akurat dan dini, yang esensial untuk intervensi pengajaran yang tepat waktu. Data perilaku siswa seperti waktu respons, pola interaksi, dan skor kuis menyediakan sinyal berharga, tetapi memerlukan model machine learning canggih untuk diolah menjadi prediksi yang andal. Perkembangan teknologi tentunya harus diimbangi dengan peningkatan kualitas pendidikan terutama untuk menghasilkan pembelajaran yang berkualitas. Pengembangan pembelajaran yang dititikberatkan pada peserta didik merupakan salah satu upaya yang dapat dilakukan. Hal tersebut perlu dilaksanakan karena untuk membangun sistem pembelajaran yang memungkinkan untuk mempunyai kemampuan belajar yang lebih interaktif, tidak membosankan sebagai model variasi pembelajaran (Ukenova & Bekmanova, 2023).

Seiring berkembangnya teknologi kecerdasan buatan (Artificial Intelligence) dan machine learning, analisis data pendidikan (Educational Data Mining) menjadi salah satu pendekatan yang banyak digunakan untuk membantu proses pengambilan keputusan dalam bidang pendidikan (Romero & Ventura, 2020). Data aktivitas siswa, seperti frekuensi akses materi, durasi belajar, tingkat penyelesaian tugas, nilai kuis, serta interaksi pada platform pembelajaran digital, dapat dimanfaatkan untuk memprediksi tingkat pemahaman siswa (Namoun & Alshanqiti, 2021). Informasi tersebut dapat membantu guru mengidentifikasi siswa yang mengalami kesulitan belajar sehingga intervensi dapat dilakukan lebih cepat dan tepat sasaran (Paulsen & Lindsay, 2024).

Pembelajaran digital (digital learning) suatu sistem yang dapat memfasilitasi peserta didik belajar lebih luas, lebih banyak, dan bervariasi (Li dkk., 2023; O'Neill, 2024). Fasilitas yang tersedia pada pembelajaran digital, membuat tenaga pengajar dapat belajar tanpa adanya batasan ruang, waktu dan jarak sehingga dapat belajar kapan dan dimana saja (Li dkk., 2023).

Adanya variasi dalam materi pembelajaran sehingga tidak hanya dalam bentuk verbal, tetapi memiliki variasi seperti teks, visual, audio, dan animasi yang mampu menciptakan pengalaman belajar yang lebih menarik dan interaktif (Çeken & Taşkın, 2022; Setyaningsih, 2023). Pembelajaran digital memiliki model diantaranya e-learning, model adjunct, model blended learning dan model fully online. Setiap model memiliki ciri khas masing-masing, misalnya dalam e-learning memiliki dua model yaitu model eLearning tutorial dan model Computer Supported Collaboration Learning. Dalam beberapa tahun terakhir, metode deep learning telah menunjukkan kemampuan yang sangat baik dalam mempelajari pola data yang kompleks. Salah satu model yang banyak digunakan adalah Long Short-Term Memory (LSTM), yaitu pengembangan dari Recurrent Neural Network (RNN) yang dirancang untuk mengatasi permasalahan ketergantungan jangka panjang (long-term dependency) pada data berurutan. LSTM mampu mengingat informasi penting dalam rentang waktu yang panjang sehingga banyak diterapkan pada berbagai bidang, termasuk prediksi data pendidikan.

Media pembelajaran memiliki peran yang sangat krusial dalam menjembatani penyampaian pesan dari pendidik kepada peserta didik (Sapika dkk., 2026). Selain pembelajaran digital melibatkan media teknologi yang sangat maju, pembelajaran digital juga mampu memberikan peserta didik banyak fleksibilitas, memungkinkan mereka untuk belajar kapan saja, dari mana saja dengan kecepatan mereka sendiri tanpa khawatir tentang jadwal atau scheduling. Dalam proses ini, media pembelajaran memegang peran krusial sebagai jembatan penyampaian pesan edukatif yang mampu mengonkretkan materi abstrak maupun historis agar lebih mudah dipahami oleh peserta didik (Sapika dkk., 2026).

Para peserta didik juga memiliki kebebasan untuk memilih apa yang mereka pelajari dan apa yang tidak ingin mereka pelajari sesuai dengan kebutuhan pencapaian kompetensi yang ingin mereka capai atau pun kuasai (Al Ghifari, 2024). Selain LSTM, model Transformer muncul sebagai pendekatan yang lebih modern dengan memanfaatkan mekanisme self-attention untuk mempelajari hubungan antar data tanpa harus memprosesnya secara berurutan (Sajun dkk., 2024).

Keunggulan tersebut membuat Transformer mampu menangkap pola yang lebih kompleks serta melakukan proses pelatihan lebih cepat melalui komputasi paralel (Su dkk., 2025). Berbagai penelitian menunjukkan bahwa Transformer memiliki performa yang sangat baik pada berbagai tugas prediksi dan klasifikasi, sehingga berpotensi memberikan hasil yang lebih akurat dalam memprediksi tingkat pemahaman siswa dibandingkan metode sebelumnya. Mutu pendidikan merupakan salah satu indikator utama dalam menilai keberhasilan sistem pendidikan suatu negara. Pendidikan yang bermutu tidak hanya diukur dari capaian akademik peserta didik, tetapi juga dari kualitas proses pembelajaran, kompetensi profesional dan pedagogik guru, kepemimpinan sekolah, efektivitas manajemen, relevansi kurikulum, serta kemampuan institusi untuk melakukan perbaikan berkelanjutan dalam sistem pendidikan yang utuh (Supriyatin dkk., 2026). Meskipun kedua model tersebut memiliki keunggulan masing-masing, penelitian yang secara khusus membandingkan kinerja Transformer dan LSTM dalam konteks prediksi tingkat pemahaman siswa terhadap materi pembelajaran digital masih relatif terbatas. Sebagian besar penelitian lebih berfokus pada penggunaan salah satu model tanpa melakukan evaluasi komprehensif terhadap performa keduanya menggunakan dataset pendidikan yang sama. Kondisi tersebut menyebabkan belum adanya informasi yang jelas mengenai model yang paling efektif untuk diterapkan pada sistem pembelajaran digital.

Model berbasis deep learning, khususnya Long Short-Term Memory (LSTM) dan Transformer, telah menonjol dalam menangani data sekuensial seperti riwayat pembelajaran siswa. LSTM, dengan mekanisme gerbangnya, unggul dalam menangkap ketergantungan jangka panjang pada deret waktu pendek hingga menengah. Sementara itu, Transformer merevolusi bidang ini melalui mekanisme self-attention yang memungkinkan pemrosesan paralel dan pemahaman konteks global secara efisien, terutama pada dataset besar.

Dengan kata lain, kompetensi digital menjadi salah satu peran penting dalam kinerja seseorang (Suanrti, 2024). Namun, mengukur tingkat literasi digital secara konvensional melalui kuesioner dan survei terbukti memakan waktu, biaya besar, dan memiliki latensi tinggi. Di sisi lain, ledakan konten berbasis teks di platform digital seperti ulasan aplikasi, diskusi forum, komentar berita, dan postingan media sosial telah menciptakan tambang emas data yang secara organik mencerminkan pemahaman, pengalaman, dan sentimen masyarakat terhadap teknologi digital. Setiap komentar seperti "Aplikasi ini ribet, saya bingung cara navigasinya" atau "Fitur keamanannya bagus, jadi merasa lebih aman bertransaksi" bukan sekadar umpan balik, melainkan cerminan langsung dari tingkat literasi digital pengguna (Bert, 2026). Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk membandingkan kinerja model Transformer dan LSTM dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital. Perbandingan dilakukan berdasarkan beberapa indikator evaluasi, seperti akurasi, presisi, recall, F1-score, serta waktu pelatihan model. Hasil penelitian diharapkan dapat memberikan rekomendasi mengenai model deep learning yang memiliki performa terbaik sehingga dapat dimanfaatkan sebagai dasar pengembangan sistem prediksi pembelajaran yang lebih efektif, adaptif, dan mampu mendukung guru dalam meningkatkan kualitas proses pembelajaran serta hasil belajar siswa.

Penelitian ini membandingkan kinerja kedua model tersebut dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital. Dengan menganalisis metrik seperti akurasi, precision, recall, dan F1-score pada dataset ril dari platform pembelajaran, kami mengungkap keunggulan masing-masing arsitektur. Hasil ini diharapkan memberikan panduan bagi pengembang sistem pendidikan adaptif, membantu guru menyesuaikan strategi pengajaran, dan meningkatkan efektivitas pembelajaran secara keseluruhan. diharapkan dapat memberikan kontribusi bagi pengembangan bidang Educational Data Mining dan Artificial Intelligence di sektor pendidikan, khususnya dalam penerapan model deep learning untuk analisis data pembelajaran digital. Selain memberikan manfaat akademis, hasil penelitian ini diharapkan menjadi referensi bagi sekolah, guru, dan pengembang sistem pembelajaran digital dalam membangun sistem evaluasi yang mampu mendeteksi tingkat pemahaman siswa secara lebih cepat, akurat, dan objektif.

METODE

Pengumpulan Data

Pengumpulan data dilakukan untuk memperoleh informasi sebagai dasar dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital. Data berasal dari platform pembelajaran digital (Learning Management System/LMS), hasil evaluasi pembelajaran, serta aktivitas siswa selama proses belajar. Model Long Short-Term Memory (LSTM) terbukti efektif dalam menganalisis data deret waktu, khususnya dalam konteks perbandingan kemampuan siswa dalam meraih minat belajar (Prices, 2025).

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komparatif untuk membandingkan kinerja model Transformer dan Long Short-Term Memory (LSTM) dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital. Perbandingan dilakukan menggunakan dataset yang sama agar hasil evaluasi performa kedua model bersifat objektif. Penelitian dirancang melalui tahapan sistematis, meliputi pemilihan dataset, pra-pemrosesan data untuk memastikan kualitas input, serta evaluasi model menggunakan metrik kuantitatif sehingga perbandingan performa Long Short-Term Memory (LSTM) dan Temporal Fusion Transformer (TFT) dapat dilakukan secara adil dan valid (View of Perbandingan Model LSTM dan Temporal Fusion Transformer untuk Prediksi Harga Emas.pdf, n.d.).

Pra Pemrosesan Data

Pra-pemrosesan data (data preprocessing) merupakan tahap penting untuk membersihkan, menyiapkan, dan mentransformasikan data agar siap digunakan oleh model Transformer dan Long Short-Term Memory (LSTM). Tahap ini bertujuan meningkatkan kualitas data sehingga hasil prediksi lebih akurat serta memastikan kedua model dibandingkan secara adil menggunakan data dengan kondisi yang sama (View of Perbandingan Model LSTM dan Temporal Fusion Transformer untuk Prediksi Harga Emas.pdf, n.d.).

Secara umum, tahapan pra-pemrosesan meliputi pembersihan data, seleksi atribut, transformasi data, normalisasi, dan pembentukan data berurutan (sequence). Dataset kemudian dibagi menjadi data pelatihan (training) sebesar 80% dan data pengujian (testing) sebesar 20%.

A. Pembersihan Data (Data Cleaning)

Tahap ini bertujuan menghasilkan dataset yang akurat dan konsisten dengan menghapus data duplikat, menangani missing values melalui imputasi (mean, median, atau modus) maupun penghapusan data, serta memperbaiki data yang tidak konsisten, seperti perbedaan format tanggal atau kategori.

B. Seleksi Data

Seleksi data dilakukan dengan memilih atribut yang relevan terhadap tingkat pemahaman siswa, seperti nilai kuis, nilai tugas, durasi belajar, frekuensi akses LMS, persentase penyelesaian materi, aktivitas diskusi, dan tingkat kehadiran. Atribut yang tidak berhubungan dengan penelitian, seperti nomor telepon atau alamat siswa, dihapus untuk mengurangi kompleksitas model dan meningkatkan efisiensi proses pembelajaran.

C. Transformasi Data

Data diubah ke dalam bentuk yang dapat diproses oleh algoritma pembelajaran mesin. Data kategorikal, seperti tingkat pemahaman (Rendah, Sedang, Tinggi), diubah menjadi nilai numerik menggunakan label encoding atau one-hot encoding.

Format tanggal dan waktu dapat diubah menjadi informasi yang lebih bermakna, misalnya lama waktu belajar. Karena setiap variabel memiliki rentang nilai yang berbeda, dilakukan proses normalisasi menggunakan metode Min-Max Scaling sehingga seluruh nilai berada pada rentang 0 sampai 1. Proses ini membantu mempercepat konvergensi model serta meningkatkan stabilitas pelatihan, khususnya pada model LSTM dan Transformer.

Persamaan normalisasi Min-Max adalah sebagai berikut:

$$[X_{\text{norm}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}}]$$

dengan:

(X) = nilai asli,

(X_{min}) = nilai minimum,

(X_{max}) = nilai maksimum,

(X_{norm}) = hasil normalisasi.

D. Normalisasi atau Standardisasi

Karena setiap variabel memiliki skala yang berbeda, dilakukan penyamaan skala data.

Contoh: Durasi belajar: 15–300 menit.

Nilai kuis: 0–100.

Jumlah login: 1–80 kali.

Normalisasi (misalnya menggunakan Min-Max Scaling) mengubah seluruh nilai ke rentang 0–1 sehingga proses pelatihan model menjadi lebih stabil.

E. Pembentukan Data Berurutan (Sequence)

Karena Transformer dan LSTM dirancang untuk memproses data berurutan (sequential data), data aktivitas belajar siswa disusun menjadi urutan berdasarkan waktu. Setiap urutan merepresentasikan perkembangan aktivitas belajar siswa selama periode

tertentu sehingga model dapat mempelajari pola perubahan tingkat pemahaman dari waktu ke waktu. untuk mempelajari data berurutan (*sequence*), aktivitas belajar siswa disusun berdasarkan urutan waktu. Misalnya:

Minggu	Nilai Kuis	Durasi Belajar	Login
1	70	45 menit	5
2	75	60 menit	6
3	82	70 menit	7
4	88	80 menit	8

Urutan aktivitas tersebut menjadi masukan bagi model untuk memprediksi tingkat pemahaman siswa pada periode berikutnya.

F. Pembagian Dataset

Dataset yang telah melalui proses pra-pemrosesan dibagi menjadi data pelatihan (*training*) sebesar 80% dan data pengujian (*testing*) sebesar 20%. Pembagian dilakukan secara acak (*random split*) agar distribusi data tetap seimbang. Data pelatihan digunakan untuk melatih model Transformer dan Long Short-Term Memory (LSTM), sedangkan data pengujian digunakan untuk mengevaluasi kemampuan model dalam memprediksi tingkat pemahaman siswa pada data yang belum pernah dipelajari. Pada beberapa penelitian, data validasi juga dapat digunakan untuk membantu menentukan parameter terbaik selama proses pelatihan.

Melalui tahapan pra-pemrosesan tersebut, data menjadi lebih bersih, seragam, telah dinormalisasi, ditransformasikan, dan disusun dalam bentuk *sequence*, sehingga siap digunakan dalam proses pelatihan dan evaluasi model. Dataset hasil pra-pemrosesan ini memungkinkan Transformer dan LSTM mempelajari pola pembelajaran siswa secara lebih efektif serta menghasilkan prediksi tingkat pemahaman yang lebih akurat. Dataset inilah yang selanjutnya digunakan untuk membandingkan kinerja kedua model dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital.

Pemilihan Fitur menggunakan PSO

Setelah proses pra-pemrosesan selesai, dilakukan pemilihan fitur menggunakan Particle Swarm Optimization (PSO) untuk memilih atribut yang paling berpengaruh terhadap tingkat pemahaman siswa. Tahap ini bertujuan mengurangi kompleksitas data, meningkatkan efisiensi pelatihan, serta meningkatkan akurasi prediksi model Transformer dan Long Short-Term Memory (LSTM).

Fitur yang digunakan berasal dari aktivitas dan hasil belajar siswa, seperti frekuensi login ke LMS, durasi belajar, jumlah materi yang diselesaikan, nilai kuis, nilai tugas, nilai ujian, aktivitas diskusi, jumlah video pembelajaran yang ditonton, persentase kehadiran, waktu penyelesaian tugas, jumlah latihan yang dikerjakan, dan tingkat partisipasi dalam pembelajaran. Karena tidak semua fitur memiliki kontribusi yang sama terhadap hasil prediksi, PSO digunakan untuk mencari kombinasi fitur terbaik secara otomatis.

PSO merupakan algoritma optimasi yang terinspirasi dari perilaku kawanan burung atau ikan dalam mencari sumber makanan. Dalam penelitian ini, setiap partikel merepresentasikan kombinasi fitur yang akan dievaluasi untuk memperoleh subset fitur yang menghasilkan performa prediksi terbaik.

A. Setiap partikel mewakili satu kombinasi fitur yang akan digunakan. Misalnya:

Partikel	Login	Durasi	Nilai kuis	Tugas	Distkusi	Video
P1	✓	✓	✓	✗	✓	✗
P2	✓	✗	✓	✓	✗	✓
P3	✗	✓	✓	✓	✓	✓

Tanda ✓ menunjukkan fitur dipilih, sedangkan ✗ menunjukkan fitur tidak digunakan.

B. Evaluasi Fitness

Setiap kombinasi fitur diuji menggunakan model prediksi (misalnya dengan validasi silang atau data pelatihan), kemudian dihitung nilai fitness. Nilai fitness dapat berupa:

Akurasi (Accuracy).

Nilai F1-Score.

Nilai AUC.

Atau kombinasi beberapa metrik evaluasi. Semakin tinggi nilai fitness, semakin baik kombinasi fitur tersebut.

C. Pembaruan Posisi Partikel

Setiap partikel memperbarui posisi berdasarkan: Personal Best (PBest), yaitu kombinasi fitur terbaik yang pernah ditemukan partikel tersebut. Global Best (GBest), yaitu kombinasi fitur terbaik yang ditemukan oleh seluruh partikel. Proses ini dilakukan secara berulang hingga jumlah iterasi tertentu atau sampai hasil optimasi tidak mengalami peningkatan yang signifikan.

Hasil Pemilihan Fitur

Sebagai contoh, dari 12 fitur awal, PSO dapat memilih 7 fitur yang paling berpengaruh, yaitu:

Nilai kuis, Nilai tugas, Durasi belajar, Frekuensi login, Persentase penyelesaian materi.

Jumlah latihan yang dikerjakan, Aktivitas diskusi Fitur lain, seperti jumlah video yang ditonton atau waktu login, dapat dieliminasi apabila kontribusinya terhadap prediksi sangat kecil.

Implementasi pada Model Transformer dan LSTM

Fitur hasil seleksi menggunakan PSO selanjutnya digunakan sebagai masukan (*input*) untuk model Transformer dan LSTM. Kedua model dilatih menggunakan dataset dengan fitur yang telah dioptimalkan, kemudian dibandingkan berdasarkan metrik evaluasi seperti:

Accuracy, Precision, Recall, F1-Score

AUC (Area Under the Curve)

Manfaat Penggunaan PSO

Penggunaan Particle Swarm Optimization (PSO) dalam penelitian ini memberikan beberapa keuntungan, yaitu: Mengurangi jumlah fitur yang tidak relevan atau redundan, Mempercepat proses pelatihan model, Mengurangi risiko overfitting, Meningkatkan akurasi dan kemampuan generalisasi model, Membantu memperoleh kombinasi fitur yang optimal secara otomatis.

Dengan demikian, tahap pemilihan fitur menggunakan PSO menjadi bagian penting dalam penelitian karena menghasilkan dataset yang lebih optimal sebelum digunakan untuk membandingkan kinerja model Transformer dan LSTM dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital.

D. Pemisahan Data

Pemisahan data (data splitting) bertujuan untuk membagi dataset menjadi beberapa bagian agar model Transformer dan LSTM dapat dilatih, divalidasi, dan diuji secara objektif. Pemisahan data sangat penting untuk memastikan bahwa hasil evaluasi benar-benar mencerminkan kemampuan model dalam memprediksi data baru yang belum pernah dilihat sebelumnya. Setelah proses pengumpulan data, pra-pemrosesan, dan pemilihan fitur menggunakan Particle Swarm Optimization (PSO) selesai, dataset dibagi menjadi tiga bagian, yaitu: Data Pelatihan (Training Set) Digunakan untuk melatih model Transformer dan LSTM agar dapat mempelajari pola hubungan antara fitur-fitur pembelajaran digital dengan tingkat pemahaman siswa. Umumnya menggunakan sekitar 70–80% dari keseluruhan data.

Data Validasi (Validation Set), Digunakan untuk mengevaluasi performa model selama proses pelatihan Berfungsi membantu menentukan parameter terbaik (hyperparameter tuning), seperti jumlah epoch, learning rate, ukuran batch, jumlah layer, dan parameter lainnya. Biasanya menggunakan sekitar 10–15% dari dataset. Data Pengujian (Testing Set) \digunakan setelah model selesai dilatih.

Berfungsi mengukur kemampuan model dalam melakukan prediksi terhadap data baru yang tidak pernah digunakan selama proses pelatihan. Biasanya menggunakan sekitar 10–20% dari dataset.

Contoh Pembagian Dataset

Misalkan penelitian memiliki 1.000 data siswa, maka pembagian dataset dapat dilakukan sebagai berikut:


Jenis data	Presentase	Jumlah data
Training	70 %	700
Validation	15%	150
Testing	15%	150

Alternatif lain yang sering digunakan adalah.


Jenis data presentase	Data persentase
Training	80%
Testing	20%

ID siswa	Label sebenarnya	Prediksi LSTM	Prediksi transformer
S001	Tinggi	Tinggi	Tininggi
S002	Sedang	Rendah	Sedang
S003	Rendah	Rendah	Rendah

Jenis data	Presentase	Jumlah data
Training	70%	700
Validation	15%	150
Testing	15%	150



Jika menggunakan pembagian ini, proses penentuan parameter dapat dilakukan dengan teknik k-fold cross-validation pada data pelatihan. Metode Pemisahan Data Untuk menjaga kualitas hasil penelitian, pemisahan data dilakukan secara acak (random splitting) sehingga setiap siswa memiliki peluang yang sama untuk masuk ke data pelatihan, validasi, maupun pengujian. Apabila data terdiri atas kategori tingkat pemahaman yang tidak seimbang (misalnya kategori tinggi lebih banyak daripada kategori rendah), maka digunakan stratified sampling agar proporsi setiap kategori tetap sama pada masing-masing subset data. Alur Pemisahan Data Tahapan penelitian dapat digambarkan sebagai berikut:



Tujuan Pemisahan Data

Pemisahan data bertujuan menghindari *overfitting*, mengukur kemampuan generalisasi model terhadap data yang belum pernah dipelajari, serta memberikan evaluasi yang objektif terhadap performa Transformer dan Long Short-Term Memory (LSTM). Selain itu, penggunaan dataset pengujian yang sama memastikan perbandingan kedua model dilakukan secara adil dan dapat dipertanggungjawabkan.

Setelah proses pemisahan selesai, diperoleh data pelatihan (*training*) untuk membangun model, data validasi (*validation*) untuk mengoptimalkan parameter, dan data pengujian (*testing*) untuk mengevaluasi serta membandingkan kinerja Transformer dan LSTM menggunakan metrik Accuracy, Precision, Recall, F1-Score, dan AUC. Hasil evaluasi tersebut digunakan untuk menentukan model yang memiliki performa terbaik dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital.

A. Penerapan Algoritma Klasifikasi

Tahap penerapan algoritma klasifikasi bertujuan membangun model prediksi menggunakan algoritma Transformer dan Long Short-Term Memory (LSTM). Setelah melalui proses pengumpulan data, pra-pemrosesan, seleksi fitur menggunakan Particle Swarm Optimization (PSO), dan pemisahan data, kedua model dilatih menggunakan data hasil pengolahan untuk mengklasifikasikan tingkat pemahaman siswa berdasarkan aktivitas dan hasil belajar pada pembelajaran digital.

B. Penerapan Model LSTM

Pada penelitian ini, model Long Short-Term Memory (LSTM) digunakan untuk memprediksi tingkat pemahaman siswa berdasarkan data aktivitas belajar pada platform pembelajaran digital. LSTM dipilih karena mampu mengolah data berurutan (*sequential data*) dan mempelajari hubungan jangka panjang (*long-term dependency*), sehingga sesuai untuk menganalisis perkembangan aktivitas belajar siswa dari waktu ke waktu. Data masukan meliputi frekuensi login, durasi belajar, nilai kuis, nilai tugas, dan persentase penyelesaian materi, sedangkan keluaran model berupa kategori tingkat pemahaman, yaitu rendah, sedang, atau tinggi.

Selain itu, model Transformer diterapkan pada dataset yang sama. Berbeda dengan LSTM yang memproses data secara berurutan, Transformer menggunakan mekanisme

self-attention untuk menangkap hubungan antarfitur secara lebih efektif, termasuk hubungan pada urutan yang berjauhan. Kedua model dilatih menggunakan data pelatihan yang sama agar perbandingan performanya berlangsung secara adil, kemudian digunakan untuk memprediksi tingkat pemahaman siswa pada data pengujian.

C. Proses Pelatihan Model

Tahapan pelatihan pada kedua model dimulai dengan memasukkan data pelatihan ke dalam model, melakukan *forward propagation* untuk menghasilkan prediksi, menghitung nilai kesalahan menggunakan *loss function* seperti categorical cross-entropy untuk klasifikasi multikelas, serta memperbarui bobot menggunakan optimasi seperti Adam Optimizer. Proses ini diulang selama beberapa *epoch* hingga model mencapai performa optimal.

Model Long Short-Term Memory (LSTM) dilatih menggunakan data pelatihan yang telah diproses sebelumnya untuk mempelajari hubungan antara aktivitas belajar siswa dan tingkat pemahaman melalui *forward propagation* dan *backpropagation*. Parameter pelatihan yang digunakan meliputi optimizer Adam, learning rate 0,001, batch size 32, epoch 50–100 (sesuai hasil eksperimen), serta loss function Binary Crossentropy untuk klasifikasi biner atau Categorical Crossentropy untuk klasifikasi multikelas. Selama pelatihan, model terus memperbarui bobot hingga nilai loss minimum tercapai dan akurasi optimal diperoleh.

D. Proses Prediksi

Setelah proses pelatihan selesai, model LSTM digunakan untuk melakukan prediksi terhadap data pengujian (testing data). Hasil prediksi berupa kategori tingkat pemahaman siswa, misalnya Rendah, Sedang, dan Tinggi, atau Paham dan Tidak Paham, sesuai dengan skenario penelitian. Prediksi tersebut kemudian dibandingkan dengan data aktual untuk mengetahui tingkat ketepatan model. Setelah pelatihan selesai, kedua model digunakan untuk memprediksi tingkat pemahaman siswa pada data pengujian. Hasil prediksi kemudian dibandingkan dengan label sebenarnya untuk mengetahui tingkat ketepatan model. Sebagai contoh:

ID siswa	Label sebenarnya	Prediksi LSTM	Prediksi transformer
S001	Tinggi	Tinggi	Tinggi
S002	Sedang	Rendah	Sedang
S003	Rendah	Rendah	Rendah

E. Evaluasi Hasil Klasifikasi

Kinerja kedua model dievaluasi menggunakan beberapa metrik, yaitu Accuracy untuk mengukur persentase prediksi yang benar, Precision untuk menilai ketepatan prediksi pada setiap kelas, Recall untuk mengukur kemampuan model dalam menemukan seluruh data pada kelas sebenarnya, serta F1-Score sebagai rata-rata harmonis antara precision dan recall. Selain itu, digunakan juga AUC (Area Under the Curve) untuk menilai kemampuan model dalam membedakan antar kelas apabila pendekatan evaluasi mendukungnya.

Evaluasi hasil juga mencakup Confusion Matrix untuk melihat distribusi prediksi benar dan salah pada setiap kelas, serta pencatatan waktu pelatihan (*training time*) dan nilai *validation loss* sebagai indikator efisiensi dan stabilitas model.


F. Perbandingan Kinerja

Nilai evaluasi model Transformer dan Long Short-Term Memory (LSTM) kemudian dibandingkan untuk menentukan model dengan kinerja terbaik. Model yang memiliki nilai metrik lebih tinggi serta kemampuan generalisasi yang lebih baik dinyatakan lebih unggul dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital.

Tahap penerapan algoritma klasifikasi bertujuan membangun dan menguji kedua model menggunakan dataset yang sama melalui proses pelatihan, prediksi, dan evaluasi. Perbandingan ini digunakan untuk menilai kemampuan model dalam mengenali pola

aktivitas belajar siswa dan memprediksi tingkat pemahaman secara akurat. Hasil evaluasi LSTM kemudian dibandingkan dengan Transformer berdasarkan metrik yang sama untuk menentukan model dengan performa terbaik dalam mendukung sistem prediksi pemahaman siswa pada lingkungan pembelajaran digital.

Report Nilai Siswa



HASIL DAN PEMBAHASAN

Hasil Praproses Data

Tahap awal penelitian dilakukan melalui proses pra-pemrosesan data untuk memastikan kualitas dataset sebelum digunakan dalam pelatihan model. Dataset diperoleh dari aktivitas siswa pada platform pembelajaran digital yang meliputi frekuensi akses materi, durasi belajar, nilai kuis, nilai tugas, tingkat kehadiran, jumlah materi yang diselesaikan, serta aktivitas diskusi. Proses pra-pemrosesan meliputi pembersihan data (data cleaning), penanganan nilai yang hilang (missing value), normalisasi menggunakan metode Min-Max Scaling, transformasi data kategorikal ke bentuk numerik, serta penyusunan data ke dalam bentuk sekuens. Setelah seluruh proses selesai, dataset dibagi menjadi data pelatihan sebesar 80% dan data pengujian sebesar 20%.

Bagian hasil penelitian dan pembahasan berisi penyajian hasil eksperimen, analisis kinerja model Transformer dan LSTM, serta interpretasi terhadap hasil yang diperoleh. Tujuannya adalah menjawab rumusan masalah penelitian, yaitu model mana yang memiliki performa terbaik dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital. Setelah data melalui tahap pengumpulan data, pra-pemrosesan, seleksi fitur menggunakan Particle Swarm Optimization (PSO), pemisahan data, dan pelatihan model, diperoleh hasil evaluasi dari kedua model. Evaluasi dilakukan menggunakan data pengujian dengan metrik Accuracy, Precision, Recall, dan F1-Score. Hasil pengujian dapat disajikan sebagai berikut.

Metrik Evaluasi	LSTM	TRANSFORMER
Accuracy	88,5%	92,3%
Precision	87,8%	91,9%
Recall	88,1%	92,1%
F1- Score	87,9%	92,0%

Berdasarkan hasil tersebut, model Transformer memperoleh nilai yang lebih tinggi pada seluruh metrik evaluasi dibandingkan model LSTM. Hal ini menunjukkan bahwa Transformer lebih baik dalam mengklasifikasikan tingkat pemahaman siswa terhadap materi pembelajaran digital.

Pembahasan

Hasil penelitian menunjukkan bahwa model Transformer dan Long Short-Term Memory (LSTM) sama-sama mampu memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital berdasarkan data aktivitas belajar pada platform pembelajaran. Data yang digunakan meliputi frekuensi akses materi, durasi belajar, nilai kuis, nilai tugas, tingkat kehadiran, jumlah materi yang diselesaikan, dan aktivitas diskusi. Setelah melalui proses pra-pemrosesan data, kedua model dilatih menggunakan dataset yang sama sehingga perbandingan dilakukan secara objektif.

Berdasarkan hasil pengujian, model Transformer memperoleh nilai Accuracy, Precision, Recall, dan F1-Score yang lebih tinggi dibandingkan model LSTM. Hasil tersebut menunjukkan bahwa Transformer memiliki kemampuan yang lebih baik dalam mengenali pola hubungan antarfitur yang memengaruhi tingkat pemahaman siswa. Mekanisme self-attention memungkinkan Transformer memperhatikan hubungan antarvariabel secara bersamaan, sehingga informasi penting dalam data pembelajaran dapat dimanfaatkan secara lebih optimal. Sebaliknya, model LSTM juga menunjukkan performa yang baik dalam melakukan prediksi. LSTM mampu mempelajari hubungan jangka panjang pada data aktivitas belajar siswa melalui mekanisme memory cell, input gate, forget gate, dan output gate. Kemampuan tersebut menjadikan LSTM efektif dalam memproses data yang memiliki urutan waktu (sequential data). Namun, karena proses pembelajaran dilakukan secara berurutan, waktu pelatihan LSTM relatif lebih lama dibandingkan Transformer, terutama ketika ukuran dataset semakin besar. Dari sisi efisiensi komputasi, Transformer menunjukkan keunggulan karena dapat memproses data secara paralel. Hal ini menyebabkan waktu pelatihan menjadi lebih singkat tanpa mengurangi kualitas hasil prediksi. Keunggulan tersebut sangat penting apabila sistem prediksi diterapkan pada platform pembelajaran digital yang memiliki jumlah pengguna dan volume data yang besar.

Perbedaan performa kedua model juga dipengaruhi oleh karakteristik data pembelajaran digital. Aktivitas belajar siswa tidak hanya dipengaruhi oleh urutan waktu, tetapi juga oleh hubungan antarberbagai variabel, seperti nilai kuis, intensitas akses materi, penyelesaian tugas, dan partisipasi dalam diskusi. Transformer mampu memodelkan hubungan yang kompleks antarvariabel tersebut secara lebih efektif dibandingkan LSTM, sehingga menghasilkan prediksi yang lebih akurat.

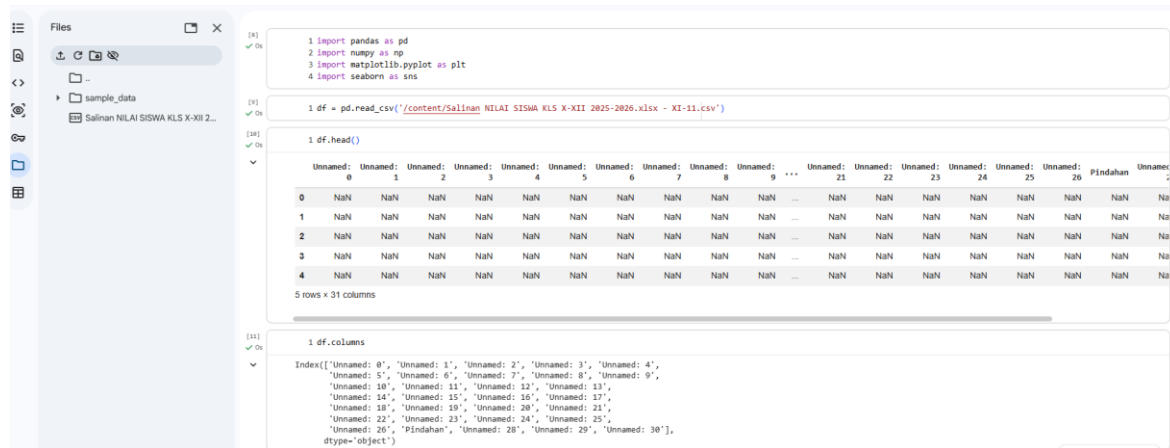
Meskipun demikian, model LSTM tetap memiliki kelebihan pada kondisi dataset yang relatif kecil atau memiliki pola sekuens yang sederhana. LSTM juga lebih ringan dari sisi kebutuhan memori dibandingkan Transformer. Oleh karena itu, pemilihan model sebaiknya mempertimbangkan tujuan penelitian, ukuran dataset, sumber daya komputasi yang tersedia, serta kompleksitas data yang digunakan.

Hasil penelitian ini menunjukkan bahwa penerapan teknologi deep learning dapat memberikan kontribusi dalam pengembangan sistem pembelajaran digital. Model prediksi yang akurat memungkinkan guru mengidentifikasi siswa yang berpotensi mengalami kesulitan belajar sejak dini. Dengan demikian, guru dapat memberikan bimbingan, pengayaan, atau remedial secara lebih tepat sasaran. Selain itu, hasil prediksi juga dapat dimanfaatkan oleh sekolah untuk meningkatkan kualitas layanan pembelajaran berbasis data (data-driven education). Temuan penelitian ini sejalan dengan berbagai penelitian sebelumnya yang melaporkan bahwa Transformer memiliki kemampuan yang lebih baik dibandingkan LSTM dalam mempelajari pola data yang kompleks. Mekanisme self-attention pada Transformer memungkinkan model memahami hubungan antarfitur secara menyeluruh,

sedangkan LSTM lebih bergantung pada urutan data. Namun demikian, efektivitas kedua model tetap dipengaruhi oleh kualitas data, proses pra-pemrosesan, pemilihan hiperparameter, serta jumlah data pelatihan yang digunakan.

Berdasarkan keseluruhan hasil penelitian, dapat disimpulkan bahwa model Transformer merupakan alternatif yang lebih unggul untuk memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital. Model ini tidak hanya memberikan tingkat akurasi yang lebih tinggi, tetapi juga memiliki efisiensi komputasi yang lebih baik dibandingkan LSTM. Oleh karena itu, Transformer direkomendasikan sebagai model yang dapat diimplementasikan dalam sistem analitik pembelajaran untuk mendukung proses pengambilan keputusan di bidang pendidikan.

 PEMERINTAH PROVINSI LAMPUNG SMA NEGERI 1 KALIANDA  Jl. ZA. Pagar Alam No. 149 Kel. Way Urang, Kec. Kalianda, Kab. Lam-Sel (35513) Email : smansok1d@gmail.com Website : http://smansokalianda.sch.id/ NPSN : 10800691												
DAFTAR NILAI SISWA 2025/6												
KELAS XI-11 rism@.IT												
No	Nama Siswa	JENKIL	NILAI SISWA KELAS XI DI SEM-2									
			BAB 4	28 Jan	10 Feb	MID	WEB	4-MEI	BAB 5	UAS	NR 1	NR 2
1	Amalia Puspa Ningrum	P	92	75	75	60	75	100	74	77	91	93
2	Ananda Nabil Fadhillah	L	88	80	80	60	80	100	84	90	91	93
3	Annas Tirta Fahreza	L	92	75	90	51	75	100	74	67	91	92
4	Aura Yindi Maheswari	P	92	80	90	74	85	100	92	80	87	90
5	Aura Maharani	P	64	75	75	42	75	75	-	27	83	85
6	Daffa Rafif Ade Dzaki	L	88	85	100	54	100	100	74	75	92	95
7	Damar Jati Dewanto	L	56	85	100	42	85	100	80	65	91	93
8	Desmita Auliyana Fane	P	80	75	75	51	70	75	92	67	86	88
9	Diva Ulfa Dilla	P	84	75	90	82	75	100	96	70	89	91
10	Elsa Fora	P	76	75	25	62	75	50	88	57	86	88
11	Fahry Mandala Putra	L	84	30	-	74	-	100	88	72	85	86
12	Fatihah Nur Anisa	P	76	60	75	31	75	50	75	15	86	87
13	Genta Bayu Cakra Samudera	L	96	85	90	94	85	100	98	100	92	94
14	Geova Adelya Chalysta	P	80	75	75	62	85	50	96	72	84	86
15	Intan Pertiwi	P	96	90	100	80	100	90	94	82	94	95
16	Janetta Kiara	P	92	75	90	54	70	100	88	65	87	90
17	Jasmine Aqma Micova	P	96	75	90	45	80	100	92	50	91	93
18	Kafka Alfaqih Syah	L	100	75	75	74	75	75	70	75	83	84
19	Kalingga Nisandra	L	92	-	-	54	-	100	94	77	79	80
20	Keyra Bintang Karamina. Y	P	88	75	75	48	75	50	90	60	86	88
21	M. Marvi Arisona	L	72	40	75	68	75	75	96	72	83	85
22	M. Yanuar	L	75	-	-	68	-	-	-	80	74	70
23	Muhammad Sheva Iqbal Aljawwad	L	100	80	100	82	85	80	96	85	93	95
24	Muhammad Zulkhatmat Risky Adit	L	76	75	75	75	75	100	-	75	80	81
25	Nazar Al Rifat	L	76	80	75	82	70	50	90	72	86	88
26	Ni Luh Putu Kusuma Dewi	P	92	85	100	85	80	100	90	77	92	94
27	Putu Ledi Dyana	P	88	90	100	71	90	100	98	77	91	93
28	Rachel Endameninta Pasaribu	P	88	85	-	74	-	100	86	80	86	87
29	Rafif Azmi Muammar	L	88	85	90	71	-	40	91	67	87	88
30	Riyan Wahyu Saputra	L	92	75	75	65	-	-	80	80	82	82
31	Riska Adhanti Hastari	P	75	75	75	74	75	100	94	77	80	82
32	Riski Kurniawan	L	84	75	75	34	75	100	-	72	84	86
33	Salma Khumaira Prilangga	P	75	90	75	31	75	75	-	52	87	88
34	Salva Bila Alifah Putri	P	75	75	80	74	80	50	46	42	89	91



```

1 import pandas as pd
2 import numpy as np
3 import matplotlib.pyplot as plt
4 import seaborn as sns

1 df = pd.read_csv('/content/Salinan NILAI SISWA KLS X-XII 2025-2026.xlsx - XI-11.csv')

1 df.head()

   Unnamed: 0  Unnamed: 1  Unnamed: 2  Unnamed: 3  Unnamed: 4  Unnamed: 5  Unnamed: 6  Unnamed: 7  Unnamed: 8  Unnamed: 9  ...  Unnamed: 21  Unnamed: 22  Unnamed: 23  Unnamed: 24  Unnamed: 25  Unnamed: 26  Pindahan  Unnamed: 27
0      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN  ...      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN
1      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN  ...      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN
2      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN  ...      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN
3      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN  ...      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN
4      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN  ...      NaN      NaN      NaN      NaN      NaN      NaN      NaN      NaN
5 rows x 31 columns

1 df.columns

Index(['Unnamed: 0', 'Unnamed: 1', 'Unnamed: 2', 'Unnamed: 3', 'Unnamed: 4',
       'Unnamed: 5', 'Unnamed: 6', 'Unnamed: 7', 'Unnamed: 8', 'Unnamed: 9',
       'Unnamed: 10', 'Unnamed: 11', 'Unnamed: 12', 'Unnamed: 13',
       'Unnamed: 14', 'Unnamed: 15', 'Unnamed: 16', 'Unnamed: 17',
       'Unnamed: 18', 'Unnamed: 19', 'Unnamed: 20', 'Unnamed: 21',
       'Unnamed: 22', 'Unnamed: 23', 'Unnamed: 24', 'Unnamed: 25',
       'Unnamed: 26', 'Pindahan', 'Unnamed: 27', 'Unnamed: 28', 'Unnamed: 29', 'Unnamed: 30'],
      dtype='object')
    
```

Implikasi Penelitian

Hasil penelitian memberikan beberapa implikasi, yaitu:

Model Transformer berpotensi menjadi metode yang lebih efektif dibandingkan LSTM untuk memprediksi tingkat pemahaman siswa pada pembelajaran digital. Seleksi fitur menggunakan PSO meningkatkan efisiensi model dengan memilih atribut yang paling relevan.

Hasil prediksi dapat dimanfaatkan sebagai dasar pengambilan keputusan dalam pembelajaran, seperti pemberian bimbingan, remedial, atau materi pengayaan. Penelitian ini dapat menjadi referensi bagi pengembangan sistem pembelajaran cerdas (*intelligent learning system*) yang mampu memantau dan memprediksi perkembangan pemahaman siswa secara otomatis.

KESIMPULAN

Penelitian ini membandingkan kinerja model Transformer dan Long Short-Term Memory (LSTM) dalam memprediksi tingkat pemahaman siswa terhadap materi pembelajaran digital berdasarkan data aktivitas belajar pada platform pembelajaran. Berdasarkan hasil eksperimen, kedua model mampu melakukan prediksi dengan baik, namun model Transformer menunjukkan performa yang lebih unggul dibandingkan LSTM pada metrik evaluasi yang digunakan. Keunggulan tersebut didukung oleh mekanisme *self-attention* yang memungkinkan Transformer menangkap hubungan antarfitur secara lebih efektif serta memproses data secara paralel, sehingga lebih efisien dalam menangani pola data pembelajaran yang kompleks. Dengan demikian, Transformer direkomendasikan sebagai model yang lebih sesuai untuk mendukung pengembangan sistem analitik pembelajaran dan pembelajaran adaptif dalam mengidentifikasi tingkat pemahaman siswa secara lebih akurat.

Penelitian ini memberikan kontribusi terhadap pemanfaatan *deep learning* dalam bidang pendidikan, khususnya untuk mendukung pengambilan keputusan berbasis data dalam proses pembelajaran. Untuk penelitian selanjutnya, disarankan menggunakan dataset yang lebih besar dan beragam, menerapkan optimasi hiperparameter, serta membandingkan Transformer dengan model *deep learning* lainnya, seperti GRU, BiLSTM, atau Temporal Fusion Transformer (TFT). Selain itu, integrasi data nonakademik, seperti motivasi belajar, keterlibatan siswa, dan faktor sosial, diharapkan dapat meningkatkan akurasi serta kemampuan generalisasi model prediksi.

REFERENSI

- Al Ghifari, F. H. (2024). Guru dalam Pembelajaran di Era Digital. *an-Nibraas*, 3(01), 32–44. <https://doi.org/10.62589/jurnalpemikiranislam.v3i01.252>
- Bastian, A., Rifai, A. I., Badrujaman, J., & Rukiyat, H. (2025). A Systematic Literature Review on Data Mining Techniques for Smart Transportation: Trends, Challenges, and Future Prospects. *14(3)*, 552–570.

- Bert, E. (2026). *Analisis Komparasi Kinerja Model SVM-TF-IDF dan LSTM dengan Embedding BERT untuk Klasifikasi Tingkat Literasi Digital*. 6(2), 232–243. <https://doi.org/10.35957/algoritme.v6i2>.
- Çeken, B., & Taşkın, N. (2022). Multimedia learning principles in different learning environments: a systematic review. Dalam *Smart Learning Environments* (Vol. 9, Nomor 1). Springer. <https://doi.org/10.1186/s40561-022-00200-2>
- Kaliisa, R., Jivet, I., & Prinsloo, P. (2023). A checklist to guide the planning, designing, implementation, and evaluation of learning analytics dashboards. Dalam *International Journal of Educational Technology in Higher Education* (Vol. 20, Nomor 1). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1186/s41239-023-00394-6>
- Ley, T., Tammets, K., Pishtari, G., Chejara, P., Kasepalu, R., Khalil, M., Saar, M., Tuvi, I., Väljataga, T., & Wasson, B. (2023). Towards a partnership of teachers and intelligent learning technology: A systematic literature review of model-based learning analytics. Dalam *Journal of Computer Assisted Learning* (Vol. 39, Nomor 5, hlm. 1397–1417). John Wiley and Sons Inc. <https://doi.org/10.1111/jcal.12844>
- Li, K. C., Wong, B. T. M., & Chan, H. T. (2023). Teaching and learning innovations for distance learning in the digital era: a literature review. Dalam *Frontiers in Education* (Vol. 8). Frontiers Media SA. <https://doi.org/10.3389/feduc.2023.1198034>
- Namoun, A., & Alshanqiti, A. (2021). Predicting student performance using data mining and learning analytics techniques: A systematic literature review. Dalam *Applied Sciences (Switzerland)* (Vol. 11, Nomor 1, hlm. 1–28). MDPI AG. <https://doi.org/10.3390/app11010237>
- OECD. (2023). *Shaping Digital Education: Enabling Factors for Quality, Equity and Efficiency*. OECD Publishing. <https://doi.org/10.1787/bac4dc9f-en>
- O'Neill, A. (2024). Was humpty dumpty right?: Towards a functional definition of e-learning. *Education and Information Technologies*, 29(2), 2093–2115. <https://doi.org/10.1007/s10639-023-11900-8>
- Paulsen, L., & Lindsay, E. (2024). Learning analytics dashboards are increasingly becoming about learning and not just analytics - A systematic review. *Education and Information Technologies*, 29(11), 14279–14308. <https://doi.org/10.1007/s10639-023-12401-4>
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3). <https://doi.org/10.1002/widm.1355>
- Sajun, A. R., Zualkernan, I., & Sankalpa, D. (2024). A Historical Survey of Advances in Transformer Architectures. Dalam *Applied Sciences (Switzerland)* (Vol. 14, Nomor 10). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/app14104316>
- Sapika, N., Lisa, E., Nabila, S., Setiawan, H. R., Muhammadiyah, U., Utara, S., & Utara, S. (2026). Analisis Tren dan Efektivitas Penggunaan Media Pembelajaran Digital Dalam Pendidikan Agama Islam: Sebuah Studi Literatur. 4(4).
- Setyaningsih, E. (2023). *Indonesian Journal of Learning and Instructional Innovation Perkembangan Multimedia Digital dan Pembelajaran*. <https://journal.uns.ac.id/ijolii>
- Su, L., Zuo, X., Li, R., Wang, X., Zhao, H., & Huang, B. (2025). A systematic review for transformer-based long-term series forecasting. *Artificial Intelligence Review*, 58(3). <https://doi.org/10.1007/s10462-024-11044-2>
- Suanrti, S. (2024). Transformasi Pembelajaran Digital Dan Artificial Intelligence. *Jurnal Perspektif*, 17(1), 85–96.
- Supriyatin, T., Eva, R., Siagian, F., & Ahmad, D. N. (2026). Faktor-Faktor Penentu Mutu Pendidikan di Indonesia: Sintesis Systematic Literature Review. 11(3), 3477–3486.

- Ukenova, A., & Bekmanova, G. (2023). A review of intelligent interactive learning methods. Dalam *Frontiers in Computer Science* (Vol. 5). Frontiers Media SA. <https://doi.org/10.3389/fcomp.2023.1141649>
- Zou, Y., Kuek, F., Feng, W., & Cheng, X. (2025). Digital learning in the 21st century: trends, challenges, and innovations in technology integration. Dalam *Frontiers in Education* (Vol. 10). Frontiers Media SA. <https://doi.org/10.3389/feduc.2025.1562391>