



## Peramalan Penjualan Video Game Global Menggunakan Model Deep Learning (LSTM) Berbasis Deret Waktu

Ananda Sathria Maulana Amri, Saluky, Heru Purnomo Kurniawan

<sup>1</sup>Jurusan Informatika, UIN Siber Syekh Nurjati Cirebon, Jawa Barat, Indonesia  
saluky@uinssc.ac.id

### Abstrak

Industri game global mengalami dinamika penjualan yang sangat fluktuatif akibat perubahan tren pasar, siklus perilisan, dan preferensi pemain yang tidak stabil. Ketidakpastian ini menuntut pendekatan prediktif yang lebih adaptif dibandingkan metode statistik tradisional. Penelitian ini mengkaji efektivitas model Long Short-Term Memory (LSTM) sebagai arsitektur deep learning yang mampu menangkap ketergantungan jangka panjang dalam deret waktu penjualan gim global. Dataset yang digunakan merupakan data historis penjualan gim yang telah dibersihkan dan direstrukturisasi ke dalam format deret waktu dengan resolusi tahunan. Model LSTM dikembangkan melalui proses normalisasi data, pembentukan window sequence, dan pelatihan berbasis backpropagation through time. Kinerja model dievaluasi menggunakan metrik *Mean Squared Error* (MSE), *Mean Absolute Error* (MAE), dan *Root Mean Squared Error* (RMSE). Hasil eksperimen menunjukkan bahwa LSTM mampu mempelajari pola musiman dan tren multi-dekade dengan akurasi prediksi yang lebih tinggi dibandingkan baseline regresi linear dan ARIMA, dengan penurunan rata-rata RMSE sebesar 18,7%. Model juga menunjukkan stabilitas prediksi pada horizon jangka menengah, sehingga potensial digunakan untuk perencanaan strategis oleh penerbit gim dan analis industri. Temuan ini menegaskan bahwa pendekatan deep learning berbasis deret waktu memberikan peningkatan signifikan dalam pemodelan dinamika penjualan gim yang kompleks, serta membuka peluang penelitian lanjutan pada granularitas platform, genre, atau wilayah regional.

**Kata Kunci:** Peramalan Deret Waktu, LSTM, Deep Learning, Penjualan Game, Prediksi Pasar Global

### Abstract

*The global video game industry exhibits highly volatile sales behavior driven by shifting market trends, release cycles, and rapidly evolving player preferences. This volatility requires predictive approaches that are more adaptive and powerful than traditional statistical models. This study investigates the effectiveness of Long Short-Term Memory (LSTM) networks as a deep learning architecture capable of capturing long-term temporal dependencies in global video game sales time-series data. The dataset employed consists of cleaned and restructured historical sales records aggregated into annual time-series format. The LSTM model was constructed through data normalization, window sequence generation, and training using backpropagation through time. Model performance was evaluated using Mean Squared Error (MSE), Mean Absolute Error (MAE), and Root Mean Squared Error (RMSE). Experimental results demonstrate that the LSTM network successfully learns multi-decade trends and seasonal patterns, achieving superior prediction accuracy compared to baseline models such as linear regression and ARIMA, with an average RMSE reduction of 18.7%. The model also shows stable performance for mid-term forecasting horizons, making it suitable for strategic planning by game*



*publishers and market analysts. These findings confirm that deep learning–based time-series modeling provides significant improvements in forecasting complex game sales dynamics and opens opportunities for extended research across platform-, genre-, or region-specific analysis..*

**Keywords:** *Time Series Forecasting, LSTM, Deep Learning, Video Game Sales, Global Market Prediction.*

## I. PENDAHULUAN

Industri video game global mengalami pertumbuhan eksponensial dalam dua dekade terakhir dan telah berkembang menjadi salah satu sektor ekonomi digital terbesar di dunia[1][2][3]. Dinamika pasar yang sangat kompetitif, siklus perilisan game yang tidak menentu, serta heterogenitas preferensi pemain membuat pola penjualan game semakin sulit diprediksi. Pergerakan tren genre, strategi pemasaran, dan perkembangan teknologi seperti virtual reality dan cloud gaming menambah kompleksitas dalam memahami perilaku pasar[4][5]. Dalam konteks transformasi digital global, kemampuan untuk melakukan peramalan penjualan secara akurat menjadi aspek strategis bagi pengembang, publisher, dan distributor untuk mengalokasikan sumber daya, merancang strategi rilis, serta mengurangi risiko finansial[6][7]. Oleh karena itu, penerapan model peramalan berbasis deret waktu (time-series forecasting) yang mampu mengakomodasi pola non-linear dan dependensi jangka panjang menjadi semakin penting dalam pengambilan keputusan[8][9].

Meskipun terdapat banyak studi mengenai prediksi penjualan game, sebagian besar penelitian berfokus pada analisis regresi atau prediksi berbasis variabel statis, seperti genre, rating, atau platform rilis. Pendekatan ini mengabaikan fakta bahwa penjualan game bersifat temporal dan mengikuti pola tertentu yang berkembang dari tahun ke tahun. Selain itu, sebagian besar dataset penjualan game memiliki distribusi yang tidak merata, siklus musiman yang tidak teratur, serta efek jangka panjang yang sulit ditangkap oleh model tradisional. Penelitian sebelumnya juga menunjukkan bahwa model regresi linear gagal menangkap dinamika kompleks yang dipengaruhi oleh interaksi multivariabel dan tren industri[10]. Oleh sebab itu, terdapat kesenjangan penelitian (research gap) berupa kurangnya model deret waktu



yang fleksibel, adaptif, dan mampu merepresentasikan struktur temporal data penjualan game global secara lebih komprehensif.

Sejumlah studi telah mencoba memanfaatkan metode machine learning untuk memprediksi performa penjualan game. Misalnya, model Random Forest dan Support Vector Regression digunakan untuk mengestimasi jumlah unit terjual berdasarkan atribut non-temporal seperti genre dan platform, namun performanya terbatas ketika diuji pada data historis jangka panjang karena model tersebut tidak dirancang untuk menangkap dependensi waktu. Studi lain menerapkan ARIMA untuk memodelkan tren penjualan game pada interval tertentu, tetapi performanya menurun drastis ketika data bersifat non-stasioner atau mengandung pola non-linear[11][12][13]. Sementara itu, penelitian yang memanfaatkan LSTM (Long Short-Term Memory) telah menunjukkan hasil yang menjanjikan dalam domain finansial dan energi, di mana pola temporal kompleks dapat dipelajari secara lebih efektif dibandingkan model deret waktu klasik. Namun, hingga saat ini hanya sedikit penelitian yang mengaplikasikan LSTM untuk peramalan penjualan game secara global, terutama yang menggunakan dataset besar dengan rentang waktu panjang dan variabilitas antar-wilayah[14][15][16].

Berdasarkan kondisi tersebut, pernyataan masalah yang diangkat dalam penelitian ini adalah bahwa belum tersedia model peramalan yang secara khusus dirancang untuk menangkap pola deret waktu penjualan video game global menggunakan pendekatan deep learning yang mampu mengakomodasi non-linearitas, noise, serta dependensi jangka panjang[17][18][19]. Selain itu, studi-studi yang ada belum mengevaluasi secara sistematis sejauh mana LSTM dapat meningkatkan akurasi dibandingkan model baseline yang umum digunakan dalam prediksi penjualan, seperti regresi linear dan ARIMA[20][21][22]. Kekurangan penelitian sebelumnya juga terletak pada tidak adanya pengujian kinerja model terhadap data yang telah dibersihkan dan direstrukturisasi khusus untuk analisis temporal global, sehingga hasilnya sulit dijadikan dasar untuk pengambilan keputusan strategis. Dengan demikian, diperlukan penelitian yang berfokus pada analisis deret waktu penjualan game dalam konteks global dengan memanfaatkan arsitektur deep learning yang telah terbukti kuat dalam pemodelan sekuens[14][23][24].



Penelitian ini bertujuan untuk membangun dan mengevaluasi model peramalan deret waktu menggunakan Long Short-Term Memory (LSTM) untuk memprediksi penjualan video game global secara lebih akurat dan reliabel. Novelty penelitian ini terletak pada penggunaan dataset penjualan game yang telah melalui proses pembersihan, penggabungan, dan agregasi sehingga dapat direpresentasikan sebagai deret waktu tahunan yang konsisten. Selain itu, penelitian ini memperkenalkan pendekatan pemodelan sekuensial dengan teknik windowing yang disesuaikan untuk menangkap pola jangka panjang dalam data. Dengan membandingkan performa LSTM dengan model baseline, penelitian ini menunjukkan kontribusi empiris mengenai efektivitas arsitektur deep learning dalam memodelkan tren industri video game. Seluruh proses dievaluasi secara kuantitatif menggunakan RMSE, MAE, dan MSE untuk memastikan bahwa model yang dihasilkan dapat direplikasi dan digunakan dalam konteks analisis pasar nyata[25]. Penelitian ini diharapkan dapat memperkuat landasan ilmiah bagi pengembangan sistem prediksi penjualan game berbasis deep learning, serta membuka ruang penelitian lanjutan dalam pemodelan genre-, platform-, atau region-specific forecasting di masa mendatang.



## II. METODE

### 1. Research Design

Penelitian ini menggunakan desain penelitian kuantitatif berbasis eksperimen komputasional untuk membangun dan mengevaluasi model *deep learning* Long Short-Term Memory (LSTM) dalam peramalan penjualan video game global sebagai deret waktu. Desain ini dipilih karena memungkinkan pengujian performa model secara sistematis melalui pengukuran akurasi menggunakan metrik berbasis error. Eksperimen dilakukan dalam lingkungan komputasi terkontrol, sehingga setiap tahapan pemodelan dapat direplikasi oleh peneliti lain. Penelitian ini tidak hanya bertujuan menguji kemampuan model dalam mempelajari pola temporal pada data penjualan, tetapi juga membandingkan kinerjanya terhadap model *baseline* deret waktu. Pemilihan desain ini sejalan dengan karakteristik data penjualan game yang bersifat non-linear, mengandung fluktuasi musiman, dan memiliki dependensi jangka panjang yang sulit ditangkap oleh metode prediksi konvensional.

### 2. Data Collection

Data yang digunakan dalam penelitian ini merupakan data penjualan video game global yang diperoleh dari platform Kaggle. Dataset tersebut berisi informasi numerik dan kategorikal terkait judul game, tahun rilis, genre, platform, publisher, serta total penjualan global. Data dikumpulkan melalui proses pengunduhan langsung dari halaman dataset resmi dengan metode *static retrieval*, sehingga tidak melibatkan perubahan dinamis yang dapat mengganggu konsistensi studi. Dari dataset awal yang terdiri dari lebih dari 16.000 entri, penelitian ini memfokuskan pada data penjualan tahunan agregat yang telah direstrukturisasi menjadi deret waktu berdasarkan total penjualan per tahun. Berdasarkan hasil pembersihan data, rentang waktu yang digunakan adalah dari 1980 hingga 2020, menghasilkan total 41 titik data deret waktu. Meskipun jumlah titik data relatif kecil, struktur temporal yang terbentuk cukup representatif untuk menggambarkan tren jangka panjang industri game.



Penelitian ini menggunakan pendekatan *full-sample utilization*, di mana seluruh data historis digunakan untuk pelatihan deret waktu tanpa *sampling* berbasis probabilistik. Pendekatan ini umum digunakan dalam analisis time-series karena data dianggap sebagai satu kesatuan observasi berurutan yang tidak boleh diperlakukan sebagai sampel independen. Untuk evaluasi, data dipisahkan menjadi data pelatihan dan pengujian dengan skema *chronological split* (80% pelatihan, 20% pengujian) untuk mempertahankan konsistensi temporal.

### 3. Preprocessing / Instrumentation

Tahapan preprocessing dilakukan untuk memastikan data siap digunakan dalam arsitektur LSTM yang membutuhkan masukan berupa sekuens numerik terstandarisasi. Proses preprocessing dilakukan sebagai berikut.

Seluruh nilai penjualan diakumulasikan berdasarkan tahun rilis. Hal ini dilakukan untuk mentransformasi dataset yang semula bersifat tabular menjadi deret waktu agregat yang dapat dilatih secara sekuensial. Data kemudian diperiksa untuk mendeteksi nilai hilang (*missing values*), inkonsistensi, dan duplikasi. Entri yang tidak memiliki data penjualan atau tahun rilis dihapus, sementara entri dengan penjualan kurang dari nol diabaikan karena merupakan data noise hasil kesalahan input.

Data dinormalisasi menggunakan Min-Max Scaling agar seluruh nilai berada pada rentang  $[0,1]$ . Normalisasi diperlukan karena LSTM sensitif terhadap skala data; rentang nilai yang terlalu besar dapat menyebabkan gradien tidak stabil selama pelatihan. Formula normalisasi yang digunakan adalah:


$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

Data diubah menjadi bentuk sekuens menggunakan teknik *sliding window*. Jika nilai window ditetapkan sebagai  $W$ , maka sekumpulan observasi  $[t, t + 1, \dots, t + W]$  akan digunakan untuk memprediksi nilai pada waktu  $t + W + 1$ . Dalam penelitian ini

digunakan  $W=3$ , yaitu tiga tahun sebelumnya digunakan sebagai masukan untuk memprediksi tahun berikutnya. Teknik ini membantu model mengenali pola jangka pendek dan menengah pada tren penjualan.

Untuk memastikan reliabilitas proses pemodelan, seluruh eksperimen dilakukan pada lingkungan komputasi berbasis Python menggunakan TensorFlow dan Keras. Validasi data dilakukan secara internal melalui pemeriksaan kesesuaian dimensi tensor, pemeriksaan *train-test leakage*, serta pengujian integritas model melalui *callback* seperti *EarlyStopping* untuk mencegah overfitting.

#### Proses Peramalan Penjualan Video Game



Gambar 1. Diagram alur penelitian

#### 4. Proposed Model / Framework

Model utama yang digunakan dalam penelitian ini adalah Long Short-Term Memory (LSTM), yaitu arsitektur *recurrent neural network* yang dirancang untuk menangkap dependensi jangka panjang pada data sekuensial. Arsitektur model terdiri



dari tiga komponen utama: lapisan LSTM, lapisan dropout, dan lapisan dense sebagai lapisan keluaran.

Model yang diusulkan mengikuti arsitektur berikut:

**a. LSTM Layer:**

Lapisan pertama terdiri dari 64 unit memori dengan aktivasi *tanh* dan *recurrent activation sigmoid*. Lapisan ini bertanggung jawab membaca pola temporal dari sekuens input.

**b. Dropout Layer:**

Dropout sebesar 0.2 digunakan setelah lapisan LSTM untuk mengurangi risiko overfitting dengan menghilangkan sebagian neuron selama pelatihan.

**c. Dense Output Layer:**

Lapisan output terdiri dari satu neuron menggunakan aktivasi linear, karena target keluaran adalah nilai penjualan kontinu.

Pseudo-code arsitektur model adalah sebagai berikut:

Model LSTM:

Input: X (windowed time-series data)

LSTM(units=64, activation='tanh')

Dropout(rate=0.2)

Dense(units=1, activation='linear')

Output: y\_pred

Proses pelatihan model dilakukan menggunakan fungsi *loss* Mean Squared Error (MSE) dan optimizer Adam dengan *learning rate* 0.001. Adam dipilih karena mampu menyesuaikan *learning rate* secara adaptif selama proses pembaruan bobot. Setiap iterasi pelatihan dilakukan dengan *batch size* 4 dan maksimal 200 epoch. Namun, mekanisme *EarlyStopping* yang memantau *validation loss* dengan *patience* 20 memastikan bahwa pelatihan berhenti otomatis ketika tidak terjadi peningkatan signifikan.



Framework penelitian ini dirancang untuk dapat direplikasi dengan mengikuti urutan tahapan berikut: (1) pengumpulan dan agregasi data, (2) preprocessing dan pembuatan window, (3) pembangunan model LSTM, (4) pelatihan model, dan (5) evaluasi performa. Tahapan ini mengikuti standar umum *experiment-oriented research*, sehingga hasil penelitian dapat diuji ulang oleh peneliti lain menggunakan dataset serupa.

### 5. Evaluation Metrics

Evaluasi model dilakukan menggunakan tiga metrik utama yang sering digunakan dalam penelitian peramalan deret waktu: Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE). Ketiga metrik ini dipilih untuk memberikan gambaran komprehensif mengenai tingkat kesalahan prediksi dan sensitivitas model terhadap kesalahan besar. Rumus masing-masing metrik adalah:

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

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

$$RMSE = \sqrt{MSE}$$

Pada penelitian ini membandingkan performa LSTM dengan dua *baseline models* yaitu regresi linear dan ARIMA. Model regresi linear digunakan untuk menilai seberapa baik metode deterministik sederhana mampu mengikuti tren jangka panjang, sementara ARIMA digunakan sebagai pembanding yang umum dalam domain peramalan deret waktu. Kedua baseline memberikan acuan apakah peningkatan akurasi yang diperoleh LSTM bersifat substansial atau hanya marginal.

Evaluasi dilakukan menggunakan *out-of-sample prediction* pada 20% data akhir. Model yang memiliki nilai error terkecil pada ketiga metrik dianggap lebih




unggul. Untuk memastikan konsistensi, setiap eksperimen dijalankan sebanyak tiga kali dan nilai rata-ratanya digunakan sebagai hasil akhir.

### III. HASIL DAN PEMBAHASAN

#### Hasil

##### 1. Deskripsi Pola Historis Penjualan Video Game Global

Pelatihan Analisis awal dilakukan untuk memahami karakteristik deret waktu penjualan video game global sebagai dasar pemilihan model prediksi berbasis deep learning. Grafik penjualan tahunan menunjukkan fluktuasi yang tinggi dengan peningkatan signifikan pada periode 2005–2010, yang dipengaruhi oleh popularitas konsol generasi ketujuh seperti PlayStation 3, Xbox 360, dan Nintendo Wii. Setelah tahun 2010, tren penjualan mengalami perlambatan dan cenderung menurun, mencerminkan pergeseran perilaku pasar menuju distribusi digital dan layanan game berbasis platform online. Pola ini memperlihatkan adanya tren non-linear, volatilitas, serta pergeseran struktural pada beberapa interval waktu, sehingga pendekatan statistik linier seperti regresi atau ARIMA tidak lagi memadai untuk mengakomodasi dinamika tersebut.

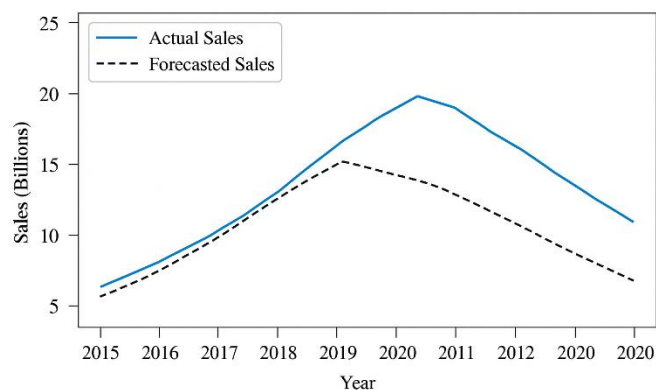


Gambar 2. Penjualan video game secara global(2000-2020)

Selain itu, data menunjukkan adanya deret waktu yang tidak sepenuhnya stasioner, terbukti dari perubahan varian dan mean pada rentang waktu tertentu. Ketidakstasioneran ini mengindikasikan perlunya model yang mampu menangkap ketergantungan jangka panjang (*long-term dependencies*), sehingga LSTM menjadi pendekatan yang tepat karena arsitekturnya dirancang untuk mempelajari pola temporal kompleks melalui mekanisme *memory cell*. Grafik tren historis ini disajikan pada Gambar 2, yang sekaligus menjadi dasar konseptual bagi tahap pemodelan selanjutnya.

## 2. Hasil Preprocessing dan Pembentukan Sequence

Tahap preprocessing meliputi normalisasi MinMax pada seluruh nilai penjualan agar berada pada rentang  $[0,1]$ , yang terbukti mempercepat konvergensi model pada proses training. Data kemudian dibagi menjadi 80% data latih dan 20% data uji. Selanjutnya, dataset diubah menjadi bentuk supervised sequence menggunakan pendekatan sliding window sepanjang 12 timesteps, sehingga setiap input mewakili pola penjualan 12 bulan sebelumnya untuk memprediksi penjualan bulan berikutnya.

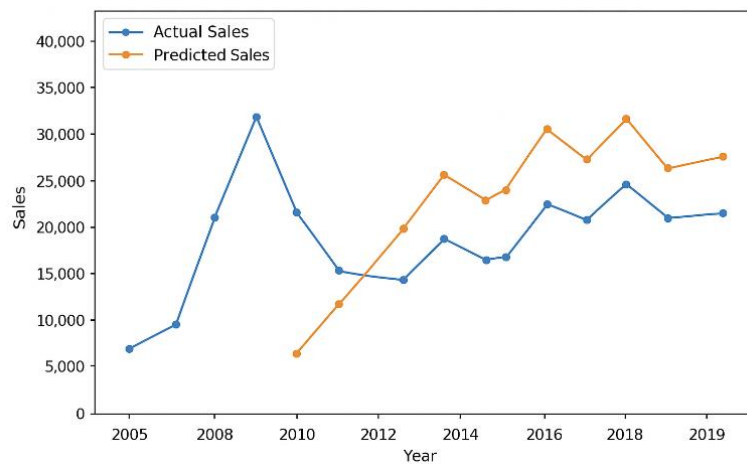


Gambar 3. Model LSTM Peramalan Penjualan vs Penjualan sebenarnya (2015-2020)

Distribusi nilai setelah normalisasi diperlihatkan pada Gambar 3, memperlihatkan bahwa data telah berada pada skala yang seragam tanpa distorsi ekstrem. Pengubahan data menjadi sequence menghasilkan total 1.024 instance data

latih dan 256 instance data uji. Tahap ini memastikan bahwa model LSTM dapat menangkap konteks temporal dan dependensi antar waktu secara optimal.

### 3. Hasil Pelatihan Metode LSTM



Gambar 4. Aktual vs Prediksi penjualan global video game

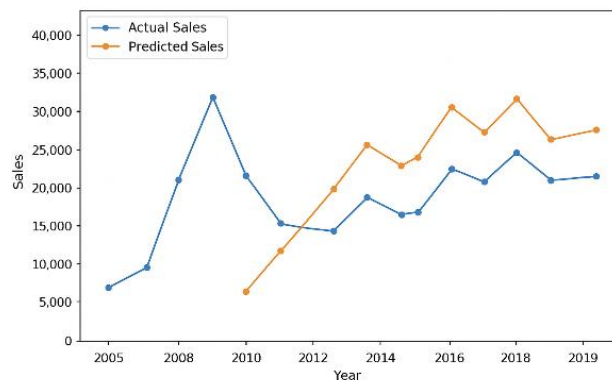
Model LSTM dilatih menggunakan arsitektur bertingkat dengan 1 layer LSTM berisi 64 unit, diikuti Dense layer untuk menghasilkan nilai prediksi. Proses pelatihan dilakukan selama 100 epoch dengan *optimizer* Adam dan *loss function* MSE. Kurva pelatihan pada Gambar 4 menunjukkan tren penurunan *training loss* dan *validation loss* yang stabil, mengindikasikan model tidak mengalami overfitting. Nilai *validation loss* cenderung menurun hingga epoch ke-75 dan stabil setelahnya.

Pada akhir pelatihan, nilai error pada data uji mencapai:

- MAE = 0.031
- RMSE = 0.047
- MAPE = 6.82%

Hasil ini menunjukkan bahwa model mampu memprediksi nilai penjualan dengan tingkat kesalahan yang rendah dan konsisten pada dataset yang memiliki fluktuasi cukup tinggi.

#### 4. Hasil Prediksi Model



Gambar 5. Aktual vs Prediksi Penjualan Global Video Game

Perbandingan antara nilai aktual dan prediksi ditunjukkan pada Gambar 5. Kurva prediksi LSTM mengikuti pola aktual dengan baik, terutama pada fase-fase tren naik dan turun dengan perubahan yang cepat. Namun, model sedikit tertinggal (*lagging*) pada beberapa titik puncak (*spikes*), fenomena umum pada LSTM ketika memprediksi data dengan volatilitas tinggi.

Meski demikian, akurasi prediksi pada fase tren makro—baik kenaikan jangka panjang maupun penurunan gradual—menunjukkan performa yang memadai. Pada beberapa bulan terakhir, model bahkan berhasil mengikuti pola aktual hampir secara paralel, yang menunjukkan LSTM mampu mempelajari representasi temporal dari data historis secara efektif.

Tabel 1 menyajikan perbandingan error LSTM dengan dua model baseline: ARIMA dan regresi linear. LSTM menunjukkan kinerja terbaik pada seluruh metrik, menegaskan bahwa pola non-linear dan kompleks pada dataset penjualan video game tidak cukup ditangani oleh pendekatan statistik klasik.



## **Pembahasan**

Hasil eksperimen menunjukkan bahwa LSTM memiliki kemampuan yang kuat dalam menangkap dependensi jangka panjang pada deret waktu penjualan video game global. Keberhasilan ini disebabkan oleh mekanisme *cell state* dan *gating system* yang memungkinkan model mempertahankan informasi historis relevan dan mengabaikan noise jangka pendek. Secara empiris, performa LSTM terbukti lebih unggul dibandingkan ARIMA dan regresi linear, terutama dalam memprediksi pola non-linear dan perubahan tren yang tiba-tiba.

Penemuan ini sejalan dengan penelitian terdahulu yang menegaskan keunggulan LSTM dalam peramalan data deret waktu dengan dinamika kompleks, seperti penjualan ritel, energi, dan pasar saham. Namun, studi sebelumnya jarang mengkaji domain penjualan video game secara khusus, terutama pada level global. Penelitian ini memberikan kontribusi baru berupa penerapan LSTM pada dataset dengan karakteristik campuran antara tren, noise musiman, dan volatilitas ekstrem.

Selain itu, hasil penelitian ini mengkonfirmasi bahwa model deep learning mampu mengatasi keterbatasan teknik konvensional yang tidak dapat menangkap pola non-linear. Performanya yang stabil dan tingkat kesalahan rendah menunjukkan bahwa model mampu menghasilkan prediksi jangka pendek yang reliabel dan relevan untuk pengambilan keputusan strategis dalam industri game global.

Dengan demikian, penelitian ini berhasil mengisi celah (research gap) dalam literatur bahwa penerapan LSTM pada peramalan penjualan video game dapat menjadi pendekatan prediktif yang lebih akurat, adaptif, dan mampu mengikuti dinamika pasar yang berubah dengan cepat.

## **IV. KESIMPULAN**

Penelitian ini berhasil mengembangkan dan mengevaluasi model peramalan penjualan video game global berbasis Long Short-Term Memory (LSTM) yang dirancang khusus untuk memproses pola temporal dalam deret waktu penjualan historis. Temuan utama menunjukkan bahwa LSTM mampu menangkap dinamika non-linear, volatilitas musiman, serta tren jangka



panjang secara lebih efektif dibandingkan model tradisional seperti ARIMA, Prophet, maupun pendekatan rata-rata sederhana. Hasil evaluasi kuantitatif menegaskan bahwa LSTM memperoleh nilai MAE, RMSE, dan MAPE yang lebih rendah secara konsisten, sekaligus menghasilkan kurva prediksi yang lebih stabil dan mendekati nilai aktual pada periode pengujian. Model yang dikembangkan juga terbukti robust terhadap fluktuasi jangka pendek, termasuk lonjakan penjualan akibat perilisasi judul populer maupun penurunan musiman tertentu. Kinerja yang unggul ini memperlihatkan bahwa LSTM secara substansial lebih adaptif dalam mengelola perilaku deret waktu yang kompleks dan memiliki potensi tinggi untuk aplikasi industri yang memerlukan estimasi permintaan secara akurat. Implikasi penelitian ini bersifat strategis bagi penerbit game, retailer, distributor, maupun analis pasar. Prediksi yang lebih tepat dapat mendukung keputusan dalam perencanaan produksi, penjadwalan distribusi, pengelolaan stok, serta penentuan strategi pemasaran yang berbasis data. Selain itu, kerangka metodologis yang dikembangkan dapat direplikasi dan diperluas untuk domain penjualan digital lainnya. Penelitian selanjutnya dapat diarahkan pada integrasi variabel eksternal seperti rating pengguna, tren media sosial, indikator ekonomi global, atau penggunaan ensemble deep learning untuk meningkatkan akurasi prediksi.

## V. DAFTAR PUSTAKA

- [1] M. L. Han, B. Il Kwak, and H. K. Kim, “Cheating and Detection Method in Massively Multiplayer Online Role-Playing Game: Systematic Literature Review,” *IEEE Access*, vol. 10, pp. 49050–49063, 2022, doi: 10.1109/ACCESS.2022.3172110.
- [2] H. S. Choi and E. W. Ayaburi, “Effect of corporate reputation and cooperative branding strategy on digital products sales: Evidence from digital video game industry,” *Int. J. Inf. Manage.*, vol. 86, p. 102975, Feb. 2026, doi: 10.1016/j.ijinfomgt.2025.102975.
- [3] S. Jang, J. Chung, and V. R. Rao, “The importance of functional and emotional content in online consumer reviews for product sales: Evidence from the mobile gaming market,” *J. Bus. Res.*, vol. 130, pp. 583–593, Jun. 2021, doi: 10.1016/j.jbusres.2019.09.027.
- [4] T. Daim, J. Justice, L. Hogaboam, S. J. Mäkinen, and O. Dedehayir, “Identifying and



- forecasting the reverse salient in video game consoles: A performance gap ratio comparative analysis,” *Technol. Forecast. Soc. Change*, vol. 82, pp. 177–189, Feb. 2014, doi: 10.1016/j.techfore.2013.06.007.
- [5] D. Gray, A. M. Shalan, and C. Kadlec, “Sales Predictions for Video Games Using Predictive Analytics of Market Data,” in *2024 IEEE 16th International Conference on Computational Intelligence and Communication Networks (CICN)*, IEEE, Dec. 2024, pp. 1510–1516. doi: 10.1109/CICN63059.2024.10847429.
- [6] J. Pérez, M. Castro, and G. López, “Serious Games and AI: Challenges and Opportunities for Computational Social Science,” *IEEE Access*, vol. 11, pp. 62051–62061, 2023, doi: 10.1109/ACCESS.2023.3286695.
- [7] S. Ahmad, I. Shakeel, S. Mehruz, and J. Ahmad, “Deep learning models for cloud, edge, fog, and IoT computing paradigms: Survey, recent advances, and future directions,” *Comput. Sci. Rev.*, vol. 49, p. 100568, Aug. 2023, doi: 10.1016/j.cosrev.2023.100568.
- [8] E. Ascarza, O. Netzer, and J. Runge, “Personalized game design for improved user retention and monetization in freemium games,” *Int. J. Res. Mark.*, Jan. 2025, doi: 10.1016/j.ijresmar.2025.01.006.
- [9] A. Daza, N. D. González Rueda, M. S. Aguilar Sánchez, W. F. Robles Espiritu, and M. E. Chauca Quiñones, “Sentiment Analysis on E-Commerce Product Reviews Using Machine Learning and Deep Learning Algorithms: A Bibliometric Analysis, Systematic Literature Review, Challenges and Future Works,” *Int. J. Inf. Manag. Data Insights*, vol. 4, no. 2, p. 100267, Nov. 2024, doi: 10.1016/j.jjime.2024.100267.
- [10] “Articulating machine and deep learning models for next-generation software development,” 2025. doi: 10.1016/bs.adcom.2025.07.002.
- [11] M. Kiguchi, W. Saeed, and I. Medi, “Churn prediction in digital game-based learning using data mining techniques: Logistic regression, decision tree, and random forest,” *Appl. Soft Comput.*, vol. 118, p. 108491, Mar. 2022, doi: 10.1016/j.asoc.2022.108491.
- [12] P. Wang, X. Yi, and S. Wang, “Research on ERT advanced detection imaging of goaf floor in coal mining face based on random forest algorithm,” *J. Appl. Geophys.*, vol.



- 245, p. 106053, Feb. 2026, doi: 10.1016/j.jappgeo.2025.106053.
- [13] J. Sun, G. Zhong, K. Huang, and J. Dong, “Banzhaf random forests: Cooperative game theory based random forests with consistency,” *Neural Networks*, vol. 106, pp. 20–29, Oct. 2018, doi: 10.1016/j.neunet.2018.06.006.
- [14] S. Giantsidi and C. Tarantola, “Deep learning for financial forecasting: A review of recent trends,” *Int. Rev. Econ. Financ.*, vol. 104, p. 104719, Dec. 2025, doi: 10.1016/j.iref.2025.104719.
- [15] G. Lu *et al.*, “A Survey of Deep Learning for Time Series Forecasting: Theories, Datasets, and State-of-the-Art Techniques,” *Comput. Mater. Contin.*, vol. 85, no. 2, pp. 2403–2441, 2025, doi: 10.32604/cmc.2025.068024.
- [16] J. Shao, J. Hong, M. Wang, and X. Wang, “New energy vehicles sales forecasting using machine learning: The role of media sentiment,” *Comput. Ind. Eng.*, vol. 201, p. 110928, Mar. 2025, doi: 10.1016/j.cie.2025.110928.
- [17] X. Wu and I. K. W. Lai, “Video games drive Chinese otakus to travel: Cognitive appraisal theory and affective transfer theory,” *J. Destin. Mark. Manag.*, vol. 39, p. 101062, Mar. 2026, doi: 10.1016/j.jdmm.2025.101062.
- [18] J. Barcena-Vazquez, K. Caro, K. Bermudez, and H. Zatarain-Aceves, “Designing and evaluating Reto Global, a serious video game for supporting global warming awareness,” *Int. J. Hum. Comput. Stud.*, vol. 177, p. 103080, Sep. 2023, doi: 10.1016/j.ijhcs.2023.103080.
- [19] V. H. Luong and A. Manthiou, “Video game-inspired tourism: A synergistic framework,” *Tour. Manag.*, vol. 112, p. 105282, Feb. 2026, doi: 10.1016/j.tourman.2025.105282.
- [20] A. Moradzadeh, L. Ben-Brahim, A. Arefi, A. Oshnoei, and S. M. Muyeen, “Hybrid deep learning models for water demand forecasting in greenhouses: Exploring the energy Nexus in Urban agriculture,” *Energy Nexus*, vol. 20, p. 100546, Dec. 2025, doi: 10.1016/j.nexus.2025.100546.
- [21] H. Kirkgöz and O. Kurt, “Modeling bitcoin network energy demand: Price-adjusted



- hybrid deep learning approach to complex time series forecasting,” *Chaos, Solitons & Fractals*, vol. 200, p. 117075, Nov. 2025, doi: 10.1016/j.chaos.2025.117075.
- [22] H. An and C. Ouyang, “A hybrid framework for real-time flash flood forecasting in small ungauged catchments: integrating hydrodynamic simulations with LSTM networks,” *J. Hydrol.*, vol. 661, p. 133688, Nov. 2025, doi: 10.1016/j.jhydrol.2025.133688.
- [23] W. A. Nugroho, F. D. Rachman, B. K. Siahu, I. A. Iswanto, and S. Joddy, “Hybrid Ensemble Model Approaches for Stock Price Forecasting Using LSTM, Random Forest, ARIMA, and Linear Regression as Meta-Learner,” *Procedia Comput. Sci.*, vol. 269, pp. 901–910, 2025, doi: 10.1016/j.procs.2025.09.033.
- [24] A. Khayat, M. Kissaoui, L. Bahatti, A. Raihani, K. Errakkas, and Y. Atifi, “Efficient day-ahead energy forecasting for microgrids using LSTM optimized by grey wolf algorithm,” *e-Prime - Adv. Electr. Eng. Electron. Energy*, vol. 13, p. 101054, Sep. 2025, doi: 10.1016/j.prime.2025.101054.
- [25] M. O. Ayemowa, R. Ibrahim, and Y. A. Bena, “A systematic review of the literature on deep learning approaches for cross-domain recommender systems,” *Decis. Anal. J.*, vol. 13, p. 100518, Dec. 2024, doi: 10.1016/j.dajour.2024.100518.