

Prediction of Budget Planning Using the Long Short Term Memory

Ahmad Nasser Ambari¹, Novianti Puspitasari^{2*}, Anindita Septiarini³

^{1,2,3}Program Studi Informatika, Fakultas Teknik, Universitas Mulawarman, Samarinda, 75119, Indonesia

Informasi Artikel

Diterima : 11 Februari 2025
Revisi : 27 Februari 2025
Publikasi : 20 Maret 2025

Kata Kunci:

LSTM
Prediksi
Properti
Penjualan
RMSE


ABSTRAK

Keputusan merupakan elemen kunci dalam manajemen perusahaan, karena perencanaan yang baik menjadi faktor penentu kesuksesannya. Salah satu aspek penting dalam perencanaan adalah prediksi penjualan. Sebuah perusahaan properti dapat mengalami kesulitan aliran kas akibat *over budget*, sehingga memaksa perusahaan untuk meninjau kembali strategi pemasaran. Penelitian ini menggunakan *Long Short Term Memory* (LSTM) untuk membantu perusahaan dalam mengurangi risiko *over budget* di masa depan. Metode *Long Short Term Memory* (LSTM) mampu menghasilkan model prediksi dengan akurasi tinggi. Data penelitian berupa data pendapatan penjualan properti dari sebanyak 107 data. Hasil pengujian menunjukkan bahwa penggunaan LSTM dengan perbandingan data latih dan data uji sebesar 90:10, 200 *epoch*, dan *learning rate* sebesar 0.005 menghasilkan nilai *Root Mean Square Error* (RMSE) terendah sebesar 0.128883554. Nilai RMSE tersebut menunjukkan bahwa metode LSTM mampu memprediksi pendapatan penjualan dengan hasil akurat yang bermanfaat bagi perusahaan. Hasil prediksi pendapatan penjualan yang terus menurun selama tiga tahun mengindikasikan bahwa perusahaan harus memperbaiki strategi pemasarannya.

ABSTRACT

Decisions are a key element in company management because good planning is a determining factor in its success. One important aspect of planning is sales prediction. A property company can experience cash flow difficulties due to *over budget*, forcing it to review its marketing strategy. This study uses Long Short-Term Memory (LSTM) to help companies reduce the risk of *over budget* in the future. The Long Short-Term Memory (LSTM) method can produce a prediction model with high accuracy. The research data is in the form of property sales revenue data from 107. The test results show that using LSTM with a comparison of training data and test data of 90:10, 200 epochs, and a learning rate of 0.005 produces the lowest Root Mean Square Error (RMSE) value of 0.128883554. The RMSE value shows that the LSTM method can predict sales revenue with accurate results that benefit the company. The results of the sales revenue prediction that has continued to decline for three years indicate that the company must improve its marketing strategy.

This is an open-access article under the [CC BY-SA](#) license



*Penulis Koresponden

Email: novipuspitasari@unmul.ac.id

Cara sitasi IEEE::

A. N. Ambari, N. Puspitasari, dan A. Septiarini, "Prediction of Budget Plan Using Long Short Term Memory," *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 5, no. 1, pp. 116-125, Maret 2025. doi: 10.30811/jaise.v5i1.6428

1. PENDAHULUAN

Banyaknya studi tentang data mining yang dikenal oleh para ahli untuk membangun model prediksi [1] menjadikan studi prediksi saat ini sangat penting untuk pengambilan keputusan di dalam suatu perusahaan. Perusahaan membutuhkan prediksi untuk menyusun perencanaan perolehan penjualan (pendapatan) sehingga mampu mengurangi risiko kerugian dan meningkatkan keuntungan. Prediksi sendiri menggunakan data masa lalu untuk dianalisis dengan metode tertentu sehingga mampu meramalkan masa depan [2]. Perusahaan properti di Balikpapan sering mengalami ketidakpastian dalam hal pendapatan penjualan. Kasus *over budget* pernah terjadi pada perusahaan tersebut, di mana anggaran melebihi 5% (lima persen) dari total penjualan, sehingga mengganggu arus kas yang disebabkan oleh dana perusahaan digunakan untuk berbagai keperluan promosi. Prediksi pendapatan penjualan diperlukan oleh perusahaan agar perusahaan mampu mengelola anggaran secara efisien dan mengurangi risiko *over budget* sehingga risiko dalam pengambilan keputusan dapat ditekan serta perusahaan mampu mengantisipasi masa depan.

Teknologi *machine learning* yang semakin berkembang menjadi salah satu pilihan yang tepat untuk melakukan prediksi pada kasus ini, salah satunya pada sub bidang *deep learning* dengan proses pembelajaran yang mirip dengan kinerja otak manusia [3]. Dikenal sebagai algoritma pembelajaran yang mempunyai informasi handal dan mampu membangun model yang optimal dalam melakukan prediksi, tidak hanya itu *deep learning* juga banyak digunakan seperti klasifikasi teks, pengenalan citra, serta pengenalan suara. *Deep learning* memiliki 3 macam algoritma diantaranya *Artificial Neural Network* (ANN), *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN). Salah satu varian metode RNN ialah *Long Short Term Memory* (LSTM) [4]. Pengembangan model LSTM dibuat karena model jaringan saraf dapat berpotensi menghasilkan *error gradient explosion* atau *gradient vanishing*, kedua hal tersebut yang dapat membuat algoritma menjadi kurang optimal sehingga terciptalah jaringan LSTM yang dikembangkan oleh Hochreiter & Schmidhuber pada tahun 1997 [5].

LSTM banyak digunakan dalam berbagai penelitian, seperti prediksi penggunaan listrik [6], prediksi harga komoditas pangan [7], prediksi penjualan supermarket [8], prediksi harga minyak dunia [9], prediksi penjualan produk berdasarkan temperature suhu [10], prediksi harga beras [11], serta prediksi harga bitcoin [12]. Selain itu, LSTM juga digunakan dalam berbagai penelitian lainnya [13]-[14]. Pada penelitian yang dilakukan oleh Prissy Nusaiba Yulisa, M. Al Haris, dan Prizka Risnawati Arum mengenai prediksi nilai ekspor migas di Indonesia, metode LSTM dan Gated Recurrent Unit (GRU) dibandingkan dan hasil penelitian menunjukkan bahwa LSTM memiliki akurasi tertinggi, yakni 87,2% [15]. Kemudian, penelitian oleh Sabar Sautomo dan Hilman Ferdinandus Pardede dalam memprediksi belanja pemerintah Indonesia dengan membandingkan metode LSTM dan Auto Regressive Integrated Average (ARIMA). Hasilnya menunjukkan bahwa LSTM dengan pemilihan *hyperparameter* yang tepat menggunakan tiga *hidden layer*, memberikan performa lebih baik dengan nilai RMSE sebesar 0.4820 [16]. Berdasarkan penelitian yang dipaparkan, metode LSTM terbukti dapat memecahkan berbagai kasus prediksi dengan akurasi yang tinggi. Oleh karena itu penelitian ini menggunakan metode LSTM untuk mencari model terbaik agar dapat melakukan prediksi serta memberi gambaran bagi perusahaan dalam mengambil keputusan yang tepat dan minim risiko.


2. METODE

2.1. Time Series

Time series adalah model untuk meramalkan kejadian masa depan dari data deret waktu yang dapat diamati dalam rentang waktu tertentu, data tersebut memiliki nilai yang dapat diukur dan diamati dalam waktu rentang tertentu [17]. Prediksi pola data pada *time series* dapat didasarkan pada interval harian, bulanan, tahunan, dll [18].

2.2. Long Short Term Memory

Pada algoritma RNN, perulangan menampung *output* jaringan untuk digunakan sebagai *input* pada jaringan selanjutnya, memungkinkan pengenalan pola dinamis. Namun, RNN tidak dapat menangkap *Long Term Dependencies* pada data berurutan besar, mengurangi akurasi dan prediksi [19]. Analisis Hochreiter & Schmidhuber menunjukkan bahwa struktur model RNN dapat menghasilkan *error gradient explosion* atau *vanishing* yang mengurangi optimalitas proses optimasi. Oleh karena itu, mereka mengembangkan model LSTM untuk mengatasi masalah tersebut [5]. LSTM memiliki struktur yang terdiri dari *Input Layer*, *Output Layer*, dan *Hidden layer*, sebagaimana yang terdapat pada RNN. Perbedaannya terletak pada mekanisme tambahan berupa *cell state* dan *gate units*, yang mencakup *forget gate*, *input gate* dan *output gate* [20]. Arsitektur LSTM dapat dilihat pada Gambar 1.



Gambar 1. Arsitektur Long-Short Term Mermory

Pada *forget gate* yang berguna untuk menentukan apakah informasi pada setiap data tersebut akan dihilangkan atau disimpan pada *cell state* dengan menggunakan fungsi aktivasi *sigmoid*. Kemudian data akan masuk ke dalam *input gate* untuk menentukan informasi baru yang akan disimpan pada *cell state*, dengan mengalikan hasil dari inputan menggunakan fungsi aktivasi *tanh* dan *sigmoid*. Selanjutnya nilai *cell state* diperbarui dari hasil *forget gate* dan *input gate*. Terakhir hasil dari *cell state* tersebut akan masuk ke dalam *output gate* yang berfungsi untuk memasukan bagian mana dari *cell state* sebagai *output* melalui aktivasi *sigmoid* yang dikalikan dengan hasil dari *cell state* yang menggunakan fungsi aktivasi *tanh*, hasil ini akan menjadi *hidden state* untuk layer LSTM selanjutnya, setelah mendapatkan *hidden state* maka perhitungan LSTM tersebut telah selesai. Persamaan yang digunakan pada setiap tahapan LSTM terdapat pada persamaan (1)-(6).

Forget Gate:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

Keterangan:

f_t : *forget gate*
 σ : *layer sigmoid*
 W_f : nilai bobot *forget gate*
 h_{t-1} : nilai *output* sebelumnya
 x_t : nilai *input* baru
 b_f : nilai bias *forget gate*

Input Gate:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

Keterangan:

f_t : *input gate*
 W_i : nilai bobot *input gate*
 b_i : nilai bias *input gate*

$$\bar{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

Keterangan:

\bar{C}_t : nilai sementara yang ditambahkan pada *cell state*
 W_c : nilai bobot *cell gate*
 b_c : nilai bias *cell gate*

Cell State:

$$C_t = f_t C_{t-1} + i_t \bar{C}_t \quad (4)$$

Keterangan:

C_t : nilai *cell state* baru
 C_{t-1} : nilai *cell state* lama
 f_t : hasil dari *forget gate*
 i_t : hasil dari *input gate*

Output Gate:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

Keterangan:

o_t : *output gate*
 W_o : nilai bobot *output gate*
 b_o : nilai bias *output gate*

$$h_t = o_t \tanh(C_t) \quad (6)$$

Keterangan:

h_t : nilai *output* order ke-1
 W_c : nilai *output gate*
 b_c : nilai *cell state*

2.3. Normalisasi

Normalisasi adalah proses transformasi nilai dari suatu data agar nilai suatu data berada dalam rentang nilai tertentu tanpa mengubah atau mempertahankan pola data, salah satu metode yang akan digunakan adalah *Min-Max Scaling*, metode ini melakukan transformasi linear terhadap data asli sehingga antara nilai sebelum dan sesudah diproses seimbang [21]. Persamaan *Min-Max Scaling* dapat dilihat pada persamaan (7).

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (7)$$

Keterangan:

x' : hasil transformasi nilai
 x_i : nilai data asli ke-i
 x_{min} : nilai minimum asli dari data
 x_{max} : nilai maksimal asli dari data

2.4. Root Mean Square Error

Dalam pembuatan model *machine learning*, evaluasi penting untuk mengukur akurasi model. Salah satu metode evaluasi adalah *Root Mean Square Error* (RMSE) yang menghitung akar rata-rata dari kuadrat kesalahan dibagi dengan jumlah data. Semakin kecil nilai RMSE, semakin baik performa model [20], [22]. Persamaan RMSE dapat dilihat pada persamaan (8).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (8)$$

Keterangan:

$RMSE$: nilai *Root Mean Squared Error*
 Y_i : nilai aktual
 \hat{Y}_i : nilai hasil prediksi
 i : urutan data
 n : jumlah data

2.5. Denormalisasi

Kebalikan dari normalisasi, denormalisasi digunakan untuk mengembalikan nilai yang di normalisasi menjadi nilai aktual hal ini akan mempermudah melihat perbandingan data hasil estimasi [23]. Persamaan denormalisasi dapat dilihat pada persamaan (9).

$$x_i = x'(x_{max} - x_{min}) + x_{min} \quad (9)$$

Keterangan :

- x_i : nilai denormalisasi
 x' : data yang telah dinormalisasi
 x_{min} : nilai minimum asli dari data
 x_{max} : nilai maximal asli dari data

2.6. Data Penelitian

Data yang digunakan dalam penelitian ini diperoleh dari data penjualan semi-apartemen. Data tersebut hanya mencakup variabel pendapatan dari perusahaan. Perincian data penelitian yang diperoleh dapat dilihat pada Tabel 1.

Tanggal	Pendapatan_sales (Rp)
10/2014	4.038.544.334
11/2014	11.137.046.898
12/2014	8.894.324.721
⋮	⋮
06/2023	3.709.088.996
07/2023	2.495.488.878
08/2023	2.990.227.482

Data penelitian memiliki dua variabel yaitu tanggal dan pendapatan sales dengan jumlah data sebanyak 107 data, dari bulan Oktober 2014 hingga bulan Agustus 2023.

2.7. Hyperparameter

Hyperparameter adalah salah satu aspek penting dari pembelajaran mesin, variabel yang harus dikonfigurasi terlebih dahulu sebelum melatih model oleh algoritma itu sendiri yang dapat disesuaikan untuk mencapai kinerja model yang optimal [24]. Penelitian kali ini menggunakan *hyperparameter* seperti *learning rate*, *epoch*, dan *optimizer adam*.

2.8. Anggaran Belanja

Sebuah instansi atau perusahaan pasti memiliki anggaran belanja guna mencapai tujuan perealisasi keuangan yang tepat pada masa yang akan datang, anggaran belanja disusun untuk keperluan perusahaan seperti biaya operasional, produksi, periklanan dan lain-lain. Perusahaan harus mengatur anggaran belanja untuk mencapai tujuan keuangan di masa depan [25], termasuk biaya operasional, produksi, dan periklanan. Pengaturan anggaran penting untuk mencegah *over budget* atau *under budget* yang dapat mempengaruhi kinerja perusahaan.

3. HASIL DAN PEMBAHASAN

3.1. Normalisasi Data

Sebelum memulai membangun model, data terlebih dahulu dilakukan normalisasi untuk mempermudah analisis dan pemrosesan data. Teknik yang digunakan adalah *Min-Max Scalling* dengan menggunakan persamaan (6), ke dalam *range* 0 hingga 1. Hasil normalisasi data disajikan pada Tabel 2.

Tanggal	Penjualan Pendapatan
01/10/2014	0.348587022
01/11/2014	1
01/12/2014	0.794190631
⋮	⋮
01/06/2023	0.382966335
01/07/2023	0.74103163
01/08/2023	0.467686969

3.2. Inisialisasi Parameter

Parameter yang diuji meliputi komposisi data, *learning rate*, *epoch*, dan penggunaan *Adam optimizer* sebagai metode optimasi berikut nilai parameternya.

Rasio data (Latih:Uji) : 90:10, 80:20 dan 70:30

Learning rate : 0.001, 0.003, 0.005

Epoch : 100, 150, 200

Optimizer : Adam

3.3. Skenario Model LSTM

Skenario dibuat agar mengetahui berapa banyak model yang harus dibuat sesuai dengan inisialisasi parameter pada subbab 3.2. Skenario pengujian memberikan panduan yang jelas dalam menentukan jumlah model yang perlu dibuat untuk mencakup variasi parameter yang telah ditetapkan, sehingga hasil pengujian menjadi representatif dan informatif. Skenario pengujian disajikan pada Tabel 3.

Tabel 3. Skenario Pengujian

Model	Parameter			
	Perbandingan Data		<i>Epoch</i>	<i>Learning Rate</i>
	Latih	Uji		
Model 1	90%	10%	100	0.001
Model 2				0.003
Model 3				0.005
Model 4			150	0.001
Model 5				0.003
Model 6				0.005
Model 7			200	0.001
Model 8				0.003
Model 9				0.005
Model 10	80%	20%	100	0.001
Model 11				0.003
Model 12				0.005
Model 13			150	0.001
Model 14				0.003
Model 15				0.005
Model 16			200	0.001
Model 17				0.003
Model 18				0.005
Model 19	70%	30%	100	0.001
Model 20				0.003
Model 21				0.005
Model 22			150	0.001
Model 23				0.003
Model 24				0.005
Model 25			200	0.001
Model 26				0.003
Model 27				0.005

Sesuai dengan inisialisasi parameter yang telah ditetapkan bahwa terdapat 27 model yang akan dibuat guna mengetahui model mana yang terbaik karena *optimizer* yang digunakan hanya satu yaitu *Adam Optimizer*.

3.4. Hasil Pengujian

Pada tahap ini, hasil uji coba akan dilakukan sesuai dengan skenario pada subbab 3.3. Pengujian dibagi sesuai dengan perbandingan data latih dan data uji. Hasil dari skenario model LSTM serta validasi *error* dengan menggunakan RMSE disajikan pada Tabel 4 sampai Tabel 6.

Tabel 4. Pengujian Model Terbaik LSTM dengan Rasio 90:10

Model	Parameter				RMSE	Model Terbaik
	Perbandingan Data		<i>Epoch</i>	<i>Learning Rate</i>		
	Latih	Uji				
Model 1	90%	10%	100	0.001	0.135505045	Bukan Terbaik
Model 2				0.003	0.132218197	Bukan Terbaik
Model 3				0.005	0.131557607	Bukan Terbaik
Model 4			150	0.001	0.135235960	Bukan Terbaik
Model 5				0.003	0.130562814	Bukan Terbaik
Model 6				0.005	0.130385786	Bukan Terbaik
Model 7			200	0.001	0.134269273	Bukan Terbaik

Model 8	0.003	0.129505174	Bukan Terbaik
Model 9	0.005	0.128883554	Model Terbaik

Dapat diketahui pada model LSTM dengan rasio data 90:10 memiliki penurunan RMSE ketika nilai *epoch* dan *learning rate* semakin besar. Hal ini menjadikan model ke-9 memiliki nilai RMSE terkecil dari pada model lainnya dengan nilai sebesar 0.128883554.

Tabel 5. Pengujian Model Terbaik LSTM dengan Rasio 80:20

Model	Parameter			RMSE	Model Terbaik	
	Perbandingan Data		<i>Epoch</i>			<i>Learning Rate</i>
	Latih	Uji				
Model 10	80%	20%	100	0.186846129	Bukan Terbaik	
Model 11				0.180051127	Bukan Terbaik	
Model 12			150	0.176812428	Bukan Terbaik	
Model 13				0.187229948	Bukan Terbaik	
Model 14			200	0.179255508	Bukan Terbaik	
Model 15				0.172483258	Bukan Terbaik	
Model 16				0.185833545	Bukan Terbaik	
Model 17				0.173164590	Bukan Terbaik	
Model 18				0.168106199	Model Terbaik	

Pada skenario model LSTM dengan perbandingan data 80:20, model terbaik dimiliki model ke-18 dengan nilai RMSE sebesar 0.168106199. Hal ini tidak berbeda seperti model dengan perbandingan data 90:10 ketika nilai *epoch* dan *learning rate* semakin besar, nilai RMSE mengecil.

Tabel 6. Pengujian Model Terbaik LSTM dengan Rasio 70:30

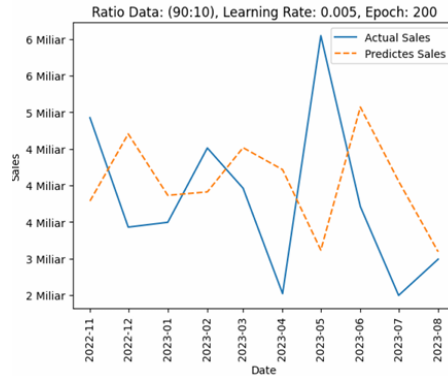
Model	Parameter			RMSE	Model Terbaik	
	Perbandingan Data		<i>Epoch</i>			<i>Learning Rate</i>
	Latih	Uji				
Model 19	70%	30%	100	0.239588054	Bukan Terbaik	
Model 20				0.239454047	Bukan Terbaik	
Model 21			150	0.236143131	Bukan Terbaik	
Model 22				0.240392378	Bukan Terbaik	
Model 23			200	0.234639947	Bukan Terbaik	
Model 24				0.229246905	Bukan Terbaik	
Model 25				0.237359223	Bukan Terbaik	
Model 26				0.232198946	Bukan Terbaik	
Model 27				0.224560354	Model Terbaik	

Berbeda dengan model-model skenario pada model LSTM dengan rasio data 70:30 model terbaik dimiliki pada model 27 dengan nilai *epoch* 200 dan *learning rate* 0.005 dengan nilai RMSE sebesar 0.224560354. Dibandingkan dengan rasio data lainnya, perbandingan data 70:30 memiliki nilai RMSE yang lebih besar. Langkah selanjutnya pemaparan tabel hasil model terbaik dari setiap skenario, yang disajikan pada Tabel 7.

Tabel 7. Pengujian Model Terbaik LSTM

Model	Parameter			RMSE	Model Terbaik	
	Perbandingan Data		<i>Epoch</i>			<i>Learning Rate</i>
	Latih	Uji				
Model 9	90%	10%	200	0.005	0.128883554	Model Terbaik
Model 18	80%	20%	200	0.005	0.168106199	Bukan Terbaik
Model 27	70%	30%	200	0.005	0.224560354	Bukan Terbaik

Dari Tabel 7, terlihat bahwa model LSTM terbaik dari ketiga perbandingan data yang telah dibangun adalah model ke-9 dengan perbandingan data 90:10, *epoch* 200 dan *learning rate* 0.005 yang menghasilkan nilai RMSE terkecil sebesar 0.128883554. Grafik prediksi model ke-9 dapat dilihat pada Gambar 2.




Gambar 2. Prediksi Model LSTM ke-9

Pada Gambar 2, model ke-9 memiliki nilai prediksi yang cukup jauh dari nilai aktual dengan data prediksi sebanyak 10 baris. Selanjutnya model ke-9 akan digunakan untuk melakukan prediksi penjualan.

3.5. Prediksi

Setelah mendapatkan model terbaik prediksi penjualan menggunakan model ke-9, model tersebut diterapkan ke dalam data penjualan untuk memprediksi penjualan ditahun berikut yaitu 2024. Grafik hasil prediksi penjualan dapat dilihat pada Gambar 3.



Gambar 3. Prediksi Penjualan Model LSTM ke-9

Gambar 3 menampilkan hasil prediksi dari tahun 2015 sampai tahun 2024. Di tahun 2021 penjualan tertinggi terjadi di bulan September sebesar Rp10.817.392.907.-, pada tahun 2022 pada bulan Juli sebesar Rp8.315.046.572.- pada tahun 2023 penjualan tertinggi pada bulan Mei sebesar Rp6.045.002.018.- dan pada awal tahun 2024 hingga pertengahan tahun penjualan pada bulan April sebesar Rp5.069.010.432.- merupakan penjualan yang tertinggi. Lebih lanjut, hasil prediksi anggaran belanja dapat dilihat pada Tabel 8. Hasil prediksi dibutuhkan dalam rangka mengetahui anggaran belanja yang dibutuhkan.

Tabel 8. Prediksi Anggaran Belanja

Tanggal	Prediksi	5% Anggaran Belanja
01/09/23	Rp3.791.333.632.-	Rp189.566.681.-
01/10/23	Rp4.723.697.152.-	Rp236.184.857.-
01/11/23	Rp3.870.093.056.-	Rp193.504.652.-
01/12/23	Rp3.870.093.056.-	Rp195.888.640.-
01/01/24	Rp4.531.717.120.-	Rp226.585.856.-
01/02/24	Rp4.226.117.376.-	Rp211.305.868.-
01/03/24	Rp3.113.615.616.-	Rp155.680.780.-
01/04/24	Rp5.100.392.448.-	Rp255.019.622.-
01/05/24	Rp4.065.599.232.-	Rp203.279.961.-
01/06/24	Rp3.091.338.240.-	Rp154.566.912.-

Tabel 8 menampilkan hasil prediksi anggaran belanja dari bulan September 2023 hingga Juni 2024. Kolom prediksi merupakan hasil dari prediksi menggunakan model yang sudah diuji, sementara untuk kolom “5% anggaran belanja” merupakan hasil 5% dari jumlah data prediksi yang dapat digunakan oleh perusahaan sebagai acuan dalam menghitung anggaran belanja untuk pengambilan keputusan.

3.5. Pembahasan

Dari 27 skenario model yang di uji coba sesuai dengan inisialisasi parameter, model ke-9 dengan rasio data latih sebanyak 90% dan data uji sebanyak 10%, *epoch* 200 dan *learning rate* 0.005 dengan nilai RMSE sebesar 0.128883554 merupakan model terbaik dalam menguji tren dari pendapatan penjualan disebuah perusahaan. Hasil prediksi menunjukkan pendapat penjualan properti menghasilkan tren penurunan dari tahun 2021 hingga 2024, hal ini juga menjadi gambaran untuk perusahaan memilih keputusan yang tepat dalam menurunkan risiko dan mendatangkan keuntungan serta mengatasi *over budget*.

4. KESIMPULAN

Penelitian ini berhasil membangun model LSTM yang optimal untuk analisis tren *time series*. Hasil uji coba menggunakan model ini menunjukkan tren menurun untuk pendapatan penjualan properti. Hasil percobaan dengan rasio data latih yang lebih sedikit, serta nilai *epoch* dan *learning rate* yang lebih besar, menghasilkan model dengan nilai evaluasi terkecil. Hasil evaluasi menunjukkan bahawa metode LSTM mampu memprediksi pendapatan penjualan suatu perusahaan dengan akurat. Hal ini tentunya bermanfaat bagi perusahaan untuk membuat keputusan dalam memperbaiki strategi pemasarannya agar pendapatan penjualan meningkat. Penelitian selanjutnya dapat mengeksplorasi metode lain seperti RNN, *Backpropagation Through Time*, dan model *machine learning* lainnya serta menguji *hyperparameter* yang berbeda atau menambahkan variabel baru yang berpengaruh terhadap hasil prediksi ke depannya.

REFERENSI

- [1] M. F. Rizkilloh and S. Widiyanesti, "Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 1, pp. 25–31, 2022, doi: 10.29207/resti.v6i1.3630.
- [2] K. Gao, Z. J. Zhou, and Y. H. Qin, "Gas Concentration Prediction by LSTM Network Combined with Wavelet Thresholding Denoising and Phase Space Reconstruction," *Heliyon*, vol. 10, no. 7, pp. 1–10, 2024, doi: 10.1016/j.heliyon.2024.e28112.
- [3] F. Zamachari and N. Puspitasari, "Penerapan Deep Learning dalam Deteksi Penipuan Transaksi Keuangan Secara Elektronik," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 2, pp. 203–212, 2021, doi: 10.29207/resti.v5i2.2952.
- [4] F. Fauzi, S. Aulia, A. R. Syaifulloh, and T. W. Utami, "Peramalan Harga Emas Menggunakan Pendekatan Long-Short Term Memory (LSTM)," *J. Edukasi dan Penelit. Inform.*, vol. 10, no. 2, pp. 252–257, 2024, doi: 10.26418/jp.v10i2.78332.
- [5] R. S. Pontoh *et al.*, "Jakarta Pandemic to Endemic Transition: Forecasting COVID-19 Using NNAR and LSTM," *Appl. Sci.*, vol. 12, no. 12, pp. 1–16, 2022, doi: 10.3390/app12125771.
- [6] N. Selle, N. Yudistira, and C. Dewi, "Perbandingan Prediksi Penggunaan Listrik dengan Menggunakan Metode Long Short Term Memory (LSTM) dan Recurrent Neural Network (RNN)," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 1, pp. 155–162, 2022, doi: 10.25126/jtiik.2022915585.
- [7] R. M. S. Adi and S. Sudioanto, "Prediksi Harga Komoditas Pangan Menggunakan Algoritma Long Short-Term Memory (LSTM)," *BUILD. Informatics, Technol. Sci.*, vol. 4, no. 2, pp. 1137–1145, 2022, doi: 10.47065/bits.v4i2.2229.
- [8] M. T. Tombeng and Z. Ardian, "Prediksi Penjualan Supermarket Menggunakan Pendekatan Deep Learning," *Cogito Smart J.*, vol. 7, no. 1, pp. 160–169, 2021.
- [9] L. S. Hasibuan and Y. Novialdi, "Prediksi Harga Minyak Goreng Curah dan Kemasan Menggunakan Algoritme Long Short-Term Memory (LSTM)," *J. Ilmu Komput. dan Agri-Informatika*, vol. 9, no. 2, pp. 149–157, 2022, doi: 10.29244/jika.9.2.149-157.
- [10] J.-K. Hong, "LSTM-Based Sales forecasting model," *KSII Trans. Internet Inf. Syst.*, vol. 15, no. 4, pp. 1232–1245, 2021, doi: 10.3837/tiis.2021.04.003.
- [11] N. Nafi'iyah and P. A. Wulandari, "Prediksi Harga Beras Berdasarkan Kualitas Beras dengan Metode LSTM," *INOVTEK Polbeng-Seri Inform.*, vol. 7, no. 2, pp. 278–288, 2022, doi: 10.35314/isi.v7i2.2599.
- [12] A. Sujjada, F. Sembiring, and F. Febriansyah, "Prediksi Harga Forex Menggunakan Algoritma Long Short-Term Memory," *Invotek Polbeng-Seri Inform.*, vol. 9, no. 1, pp. 69–76, 2024, doi: 10.36802/jnalanoka.2022.v3-no2-69-76.
- [13] A. Hanafiah, Y. Arta, H. O. Nasution, and Y. D. Lestari, "Penerapan Metode Recurrent Neural Network dengan Pendekatan Long Short-Term Memory (LSTM) Untuk Prediksi Harga Saham," *Bull. Comput. Sci. Res.*, vol. 4, no. 1, pp. 27–33, 2023, doi: 10.47065/bulletincsr.v4i1.321.
- [14] R. Gunawan, K. Valerine, M. B. Dimiliu, and S. P. Tamba, "Analisis Prediksi Penjualan Toko Furnitur dengan Metode Long Short-Term Memory (LSTM)," *TEKINKOM*, vol. 7, no. 2, pp. 716–725, 2024, doi: 10.37600/tekinkom.v7i2.1511.
- [15] N. Y. Prissy, M. Al Haris, and P. R. Arum, "Peramalan Nilai Ekspor Migas di Indonesia dengan Model Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU)," *J. Stat.*, vol. 16, no. 1, pp. 328–341, 2023.
- [16] S. Sautomo and H. F. Pardede, "Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM)," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 99–106, 2021, doi: 10.29207/resti.v5i1.2815.
- [17] E. Darnila, R. K. Dinata, and S. Ramadani, "Prediksi Harga Pasar Komoditi Tanaman Pangan di Aceh Utara pada Masa Pandemi Covid-19 dengan Metode Fuzzy Time Series Model Chen," *JTIK (Jurnal Tek. Inform. Kaputama)*, vol. 7, no. 1, pp. 17–26, 2023, doi: 10.59697/jtik.v7i1.26.
- [18] L. A. Anbar and W. Wahyudin, "Peramalan Permintaan Tas Laptop Menggunakan Model Time Series," *J. Ind. Serv.*, vol. 7, no. 2, pp. 285–288, 2022, doi: 10.36055/jiss.v7i2.14326.
- [19] R. B. R. Putra and H. Hendry, "Multivariate Time Series Forecasting pada Penjualan Barang Retail dengan Recurrent Neural Network," *Inovtek Polbeng-Seri Inform.*, vol. 7, no. 1, p. 7, 2022, doi: 10.35314/isi.v7i1.2398.
- [20] N. K. Agusmawati, F. Khoiriyah, and A. Tholib, "Prediksi Harga Emas Menggunakan Metode LSTM dan GRU," *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 11, no. 3, pp. 620–627, 2023, doi: 10.35447/jitekh.v8i1.194.

-
- [21] R. Muhammad and I. Nurhaida, "Penerapan LSTM dalam Deep Learning untuk Prediksi Harga Kopi Jangka Pendek dan Jangka Panjang," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 10, no. 1, pp. 554–564, 2025.
- [22] W. Setialaksana, D. R. A. Sulaiman, S. S. Dewi, C. A. Lamasitudju, N. R. Ashadi, and M. Asriadi, "Model Jaringan Syaraf Tiruan dalam Peramalan Kasus Positif Covid-19 di Indonesia," *J. Mediat.*, vol. 3, no. 2, p. 53, 2020, doi: 10.26858/jmtik.v3i2.14363.
- [23] Y. Setiawan, T. Tarno, and P. Kartikasari, "Prediksi Harga Jual Kakao dengan Metode Long Short-Term Memory Menggunakan Metode Optimasi Root Mean Square Propagation dan Adaptive Moment Estimation Dilengkapi Gui Rshiny," *J. Gaussian*, vol. 11, no. 1, pp. 99–107, 2022, doi: 10.14710/j-gauss.v11i1.33994.
- [24] E. T. Habtemariam, K. Kekeba, M. Martínez-Ballesteros, and F. Martínez-Álvarez, "A Bayesian Optimization-Based LSTM Model for Wind Power Forecasting in the Adama District, Ethiopia," *Energies*, vol. 16, no. 5, pp. 1–22, 2023, doi: 10.3390/en16052317.
- [25] M. Novelsyah, N. Wahyudin, and R. Rasidah, "Model Prediksi Perubahan Anggaran Belanja Daerah pada Kabupaten Kota di Kalimantan Selatan," *J. Akunt. Keuang. dan Bisnis*, vol. 15, no. 1, pp. 401–410, 2022, doi: 10.35143/jakb.v15i1.5296.