

Prediksi Jumlah Kunjungan Wisatawan Nusantara ke Sulawesi Tenggara Menggunakan Pendekatan *Machine Learning*

Kariyamin^{1*}, Sry Fasliah Hamka¹, Egi Dio Bagus Sudewo², La Ode Alyandi¹

¹Program Studi Teknologi Informasi, Institut Teknologi dan Bisnis Muhammadiyah Wakatobi, Indonesia.

²Program Studi Sistem Informasi, Universitas Royal, Indonesia.

Artikel Info

Kata Kunci:

LSTM;
Peramalan Pariwisata;
Prediksi Deret Waktu;
Sulawesi Tenggara;
SVR.

Keywords:

LSTM;
Tourism Forecasting;
Time Series Prediction;
Southeast Sulawesi;
SVR.

Riwayat Artikel:

Submitted: 04 September 2025
Accepted: 03 November 2025
Published: 04 November 2025

Abstrak: Prediksi jumlah kunjungan wisatawan merupakan aspek penting dalam perencanaan dan pengambilan kebijakan di sektor pariwisata. Penelitian ini bertujuan untuk menganalisis perbandingan kinerja model Support Vector Regression (SVR) dan Long Short-Term Memory (LSTM) dalam memprediksi jumlah kunjungan wisatawan nusantara ke Provinsi Sulawesi Tenggara. Data yang digunakan diperoleh dari Badan Pusat Statistik (BPS) Provinsi Sulawesi Tenggara periode Januari 2018 hingga Desember 2023. Model SVR dan LSTM masing-masing diuji menggunakan metrik Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE) untuk mengukur tingkat akurasi hasil prediksi. Hasil penelitian menunjukkan bahwa model SVR menghasilkan nilai RMSE dan MAE yang lebih rendah pada 13 dari 17 kabupaten/kota, sehingga memiliki tingkat akurasi yang lebih baik dibandingkan model LSTM. Sementara itu, LSTM cenderung lebih sensitif terhadap fluktuasi data yang ekstrem pascapandemi, sehingga menghasilkan prediksi yang kurang stabil. Berdasarkan hasil tersebut, dapat disimpulkan bahwa model SVR lebih sesuai digunakan untuk memprediksi jumlah kunjungan wisatawan di wilayah dengan karakteristik data yang bersifat musiman dan fluktuatif seperti Sulawesi Tenggara. Temuan ini diharapkan dapat menjadi dasar dalam pengembangan sistem prediksi pariwisata berbasis machine learning yang lebih akurat dan adaptif.

Abstract: Tourist arrival forecasting is an essential aspect of planning and policymaking in the tourism sector. This study aims to analyze and compare the performance of Support Vector Regression (SVR) and Long Short-Term Memory (LSTM) models in predicting the number of domestic tourist visits to Southeast Sulawesi Province. The data were obtained from the Statistics Indonesia (BPS) of Southeast Sulawesi Province covering the period from January 2018 to December 2023. Both SVR and LSTM models were evaluated using the Root Mean Square Error (RMSE) and Mean Absolute Error (MAE) metrics to measure the accuracy of their predictions. The results show that the SVR model produced lower RMSE and MAE values in 13 out of 17 districts/cities, indicating higher predictive accuracy compared to the LSTM model. Meanwhile, the LSTM model tended to be more sensitive to extreme data fluctuations during the post-pandemic period, resulting in less stable predictions. Based on these findings, the SVR model is considered more suitable for predicting tourist arrivals in regions with seasonal and fluctuating data characteristics, such as Southeast Sulawesi. This study is expected to serve as a basis for developing more accurate and adaptive machine learning-based tourism forecasting systems.

Corresponding Author:

Kariyamin

Email: kariyamin28@gmail.com

PENDAHULUAN

Sektor pariwisata merupakan salah satu pilar penting dalam pembangunan ekonomi, baik di level global maupun nasional. Menurut data (UNWTO, 2024) lebih dari 1,3 miliar perjalanan wisata tercatat secara global pada tahun 2022, menandai pemulihan signifikan pasca-pandemi. Di Indonesia, Badan Pusat Statistik (BPS, 2024) mencatat bahwa kunjungan wisatawan nusantara mencapai 749,1 juta perjalanan domestik pada tahun 2023, dengan peningkatan signifikan di wilayah timur, termasuk Provinsi Sulawesi Tenggara. Fenomena di lapangan menunjukkan bahwa dinamika jumlah kunjungan wisatawan di daerah tersebut masih fluktuatif. Namun demikian, fluktuasi jumlah kunjungan yang tidak terprediksi dengan baik seringkali menyulitkan pemerintah daerah dalam mengalokasikan sumber daya secara optimal, termasuk perencanaan infrastruktur, transportasi, dan promosi destinasi (Avenali et al., 2020).

Fenomena di lapangan menunjukkan bahwa instabilitas jumlah kunjungan wisatawan di Sulawesi Tenggara masih menjadi persoalan krusial. Laporan Dinas Pariwisata Provinsi Sulawesi Tenggara tahun mencatat bahwa realisasi perjalanan wisatawan nusantara tahun 2023 bahkan melampaui target hingga 139%, mencapai sekitar 9,2 juta perjalanan dari target 6,6 juta. Kondisi ini menegaskan perlunya sistem prediksi kunjungan wisata berbasis data yang akurat. Di sisi lain, perkembangan teknologi kecerdasan buatan dan *machine learning* telah membuka peluang bagi pengembangan model prediksi yang lebih presisi, seperti *Long Short-Term Memory* (LSTM) dan *Support Vector Regression* (SVR), khususnya dalam mengolah data time-series kunjungan wisata (Afrianto & Wasesa, 2022)(Salem & Khalil, 2022).

Isu ini penting untuk diteliti karena keterandalan prediksi kunjungan wisata memiliki dampak besar dalam dimensi ekonomi, sosial, dan tata kelola wilayah (Shuhua et al., 2023). Dari perspektif pembangunan daerah, kemampuan memproyeksikan arus kunjungan secara presisi akan mendukung penciptaan lapangan kerja, pertumbuhan UMKM lokal, dan efisiensi dalam perencanaan kebijakan pariwisata (Zulkifli Noor, 2022). Dari sisi teknologi, penelitian ini juga mendukung penguatan pendekatan berbasis data dalam pengambilan keputusan publik. Dengan demikian, eksplorasi lebih dalam terhadap efektivitas model LSTM dan SVR dalam konteks lokal menjadi sangat relevan, terutama untuk wilayah dengan karakteristik kunjungan wisata yang bersifat musiman dan heterogen seperti Sulawesi Tenggara.


Berbagai studi sebelumnya telah mengkaji penerapan metode prediksi berbasis *machine learning* dan statistik di berbagai sektor, termasuk energi, industri, dan ekonomi digital. Abdel-Haleem Abdel-Aty et al. (2024) mengembangkan model hibrida ARMA-LSTM dengan Discrete Wavelet Transform (DWT) untuk peramalan daya turbin angin, yang menghasilkan akurasi sebesar 99,24%. Pei Jiang et al. (2023) menggunakan model LSTM dan algoritma genetika adaptif untuk memprediksi dan mengoptimalkan konsumsi energi robot industri, dengan hasil pengurangan konsumsi energi sebesar 22,35% dan MAPE di bawah 4,21%. Dary et al. (2021) menerapkan model SARIMA untuk prediksi harga saham Apple, namun menghasilkan MAPE sebesar 36,05%, menunjukkan keterbatasan dalam akurasi real-time. Sementara itu, Sangwan dan Bhatnagar (2025) mengusulkan pendekatan multi-branch LSTM yang dikombinasikan dengan CNN-LSTM untuk prediksi popularitas video YouTube, dengan peningkatan performa melalui penurunan MAE sebesar 50% dan peningkatan R^2 sebesar 0,61%. Dalam konteks peramalan energi, Huang dan Kaewunruen (2023) menjadi pionir dalam menerapkan model transformer pada bangunan publik skala nyata. Meski transformer unggul dalam menangani data sekuensial, SVR justru menunjukkan performa lebih tinggi (R^2 0,92 vs 0,82) pada data granular 30 menit. Ini menunjukkan bahwa model sederhana seperti SVR tetap relevan untuk data deterministik dengan hubungan input-output yang kuat dalam jangka pendek. Namun, sebagian besar penelitian tersebut masih berfokus pada sektor industri dan energi, sementara penerapannya di bidang pariwisata —

khususnya untuk kasus daerah dengan pola kunjungan yang sangat fluktuatif seperti Sulawesi Tenggara—belum banyak dilakukan. Padahal, karakteristik data pariwisata bersifat musiman, non-linier, dan rentan terhadap kejadian eksternal (pandemi, cuaca, dan kebijakan daerah) yang menuntut pendekatan prediktif adaptif. Model LSTM unggul dalam menangkap pola jangka panjang dan dependensi waktu (Sun et al., 2025), sedangkan SVR lebih efisien untuk data terbatas dan pola jangka pendek (Pawar et al., 2024). Oleh karena itu, perbandingan empiris antara LSTM dan SVR pada data kunjungan wisatawan nusantara ke Sulawesi Tenggara menjadi penting untuk menentukan model yang paling sesuai dengan karakteristik data lokal dan kebutuhan perencanaan daerah. Celah penelitian ini (*literature gap*) menjadi signifikan karena belum ada kajian terdahulu yang secara sistematis membandingkan kedua metode tersebut untuk konteks pariwisata daerah di Indonesia, terutama di kawasan timur. Hasil penelitian diharapkan tidak hanya berkontribusi pada pengembangan model prediksi berbasis *machine learning* di sektor pariwisata, tetapi juga memberikan dasar empiris bagi pemerintah daerah dalam perencanaan infrastruktur dan kebijakan berbasis data.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membandingkan performa model LSTM dan SVR dalam memprediksi jumlah kunjungan wisatawan nusantara ke Provinsi Sulawesi Tenggara. Fokus kajian meliputi evaluasi akurasi model berdasarkan metrik MAE dan RMSE serta analisis tren musiman. Secara teoretis, penelitian ini diharapkan memperkaya literatur mengenai penerapan deep learning dan *machine learning* dalam konteks prediksi pariwisata regional. Secara praktis, hasil penelitian ini dapat digunakan sebagai dasar pengembangan sistem prediksi untuk mendukung pengambilan kebijakan berbasis data di sektor pariwisata daerah.

METODE


Penelitian ini menerapkan pendekatan kuantitatif berbasis data time-series dengan metode komparatif untuk menganalisis kinerja dua model *machine learning*, yakni *Long Short-Term Memory* (LSTM) (Khaira et al., 2025) dan *Support Vector Regression* (SVR) (Lima et al., 2021), dalam memprediksi jumlah kunjungan wisatawan nusantara ke Provinsi Sulawesi Tenggara. Prosedur penelitian ini dibagi ke dalam lima tahapan utama: pengumpulan data, preprocessing data, tuning hyperparameter, visualisasi dan interpretasi hasil, serta analisis hasil, alur penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

Pengumpulan Data

Data jumlah kunjungan wisatawan nusantara ke Sulawesi Tenggara diperoleh dari sumber resmi seperti Badan Pusat Statistik (BPS). Data yang dikumpulkan mencakup periode bulanan selama lima tahun terakhir (2019–2024), sehingga mampu menangkap pola musiman serta tren jangka menengah dalam pergerakan wisatawan. Pemilihan periode ini juga disesuaikan dengan ketersediaan data, karena data sebelum tahun 2019 belum dipublikasikan secara konsisten oleh BPS. Data tersebut menjadi input utama dalam proses pelatihan dan evaluasi model prediksi. Jumlah wisatawan yang datang ke Sulawesi Tenggara dapat dilihat pada Gambar 2.



Gambar 2. Grafik Kunjungan Wisatawan ke Sulawesi Tenggara

Gambar 2 menyajikan tren kunjungan wisatawan nusantara ke kawasan Sulawesi secara umum. Sementara itu, Tabel 1 menunjukkan data tahunan kunjungan ke Provinsi Sulawesi Tenggara yang telah disusun berdasarkan agregasi data bulanan. Untuk memperoleh informasi yang lebih terperinci, data kunjungan bulanan dapat diakses melalui situs resmi Badan Pusat Statistik Sulawesi Tenggara di <https://sultra.bps.go.id/id>.

Tabel 1 data tahunan kunjungan ke Provinsi Sulawesi Tenggara

Kabupaten/Kota Tujuan	Jumlah Perjalanan Wisatawan Nusantara Menurut Kabupaten/Kota Tujuan (Perjalanan)					
	2019	2020	2021	2022	2023	2024
Buton	165864	52212	86511	695931	571915	358136
Muna	350787	154987	140331	1209694	851384	623105
Konawe	529034	209611	239854	820353	698552	1335544
Kolaka	529582	88543	264823	1271278	816121	877847
Konawe Selatan	604945	233920	194001	1101438	1455264	1608505
Bombana	281161	84279	156058	549580	583436	475178
Wakatobi	115892	22524	63862	675014	557387	151362
Kolaka Utara	288808	41232	127570	461931	393587	372263
Buton Utara	72851	25582	71353	488465	356248	218536
Konawe Utara	174934	50343	174549	744500	882621	623823
Kolaka Timur	285044	100856	140174	718895	526680	499353
Konawe Kepulauan	56192	17039	70525	141267	141162	145968
Muna Barat	125128	65483	63063	418306	492877	296662

Buton Tengah	142680	74479	54207	388598	398288	380391
Buton Selatan	111465	37686	58054	520336	410973	296831
Kota Kendari	1599907	520744	515752	1838560	1413512	3730341
Kota Baubau	407123	159188	160468	738900	519940	952528

Preprocessing Data

Tahapan preprocessing melibatkan pembersihan data dari nilai kosong dan outlier menggunakan teknik interpolasi linier dan IQR filtering. Selanjutnya dilakukan normalisasi menggunakan *MinMaxScaler* agar seluruh fitur memiliki rentang skala antara 0 dan 1 (Christy & Umamakeswari, 2020)(Li et al., 2022). Normalisasi ini penting untuk menjaga kestabilan pelatihan model(Passalis et al., 2020)(Madhulika & Sampath, 2022).

Implementasi LSTM dan SVR

Penelitian ini menggunakan dua pendekatan prediktif, yakni Long Short-Term Memory (LSTM) dan Support Vector Regression (SVR). Model LSTM dirancang untuk menangkap dinamika temporal jangka panjang dan pendek dalam deret waktu (Ma & Leung, 2019), sementara SVR digunakan untuk menangkap pola regresi nonlinier dengan margin kesalahan minimum (Zhu et al., 2018). Arsitektur LSTM dibangun dengan urutan input-berbasis waktu dan target output jumlah kunjungan wisatawan pada bulan berikutnya. Data input diolah dalam bentuk urutan berjangka (*windowed sequence*) (Hanafiah et al., 2022)(Chen et al., 2021), yang memungkinkan jaringan untuk belajar dari pola historis (Lin et al., 2022). Di sisi lain, model SVR memanfaatkan fitur transformasi seperti nilai lag dan rata-rata bergerak (*rolling mean*) guna menangkap struktur musiman dan tren (Proietti et al., 2019)(He et al., 2021). Proses pelatihan kedua model dilakukan secara independen dan kemudian dibandingkan dalam hal akurasi prediksi dan efisiensi komputasi.

Hyperparameter Tuning

Dalam penelitian ini, digunakan dua algoritma pemodelan yaitu LSTM (Khaira et al., 2025) dan SVR dengan konfigurasi hyperparameter yang disesuaikan. Model LSTM dibangun menggunakan satu lapisan LSTM dengan 64 unit dan fungsi aktivasi ReLU, diikuti oleh satu lapisan Dense sebagai output. Proses pelatihan menggunakan algoritma optimasi Adam dengan fungsi kerugian *mean squared error* (MSE). Model dilatih selama 100 *epoch* dengan ukuran *batch* sebesar 32. Sementara itu, model SVR menggunakan kernel *Radial Basis Function* (RBF) dengan parameter *C* sebesar 1000 dan *gamma* disetel ke nilai *auto*, yang secara otomatis menyesuaikan dengan jumlah fitur input. Proses tuning dilakukan melalui eksperimen grid search manual terhadap kombinasi parameter yang dianggap signifikan. Pembagian data dilakukan secara berdasarkan urutan waktu, di mana data tahun 2019–2023 digunakan sebagai data latih dan data tahun 2024 sebagai data uji. Setelah evaluasi pada data uji, kedua model dilatih ulang menggunakan seluruh data hingga tahun 2024 untuk menghasilkan prediksi jumlah wisatawan periode 2025–2027.

Visualisasi dan Interpretasi Hasil

Output dari kedua model divisualisasikan dalam bentuk grafik prediksi versus realisasi, serta dilengkapi dengan *residual plot* untuk mengamati penyimpangan model dari data aktual. Metode evaluasi yang digunakan adalah *mean absolute error* (MAE) dan *root mean squared error* (RMSE) dan walk-forward validation sebagai validasi model. Visualisasi dilakukan menggunakan Python dengan library Matplotlib.

Analisis Hasil

Analisis dilakukan dengan membandingkan performa LSTM dan SVR berdasarkan tiga metrik evaluasi serta pola prediksi pada data musiman. Peneliti mengkaji kelebihan dan kelemahan dari masing-masing model, serta menyimpulkan model mana yang lebih tepat digunakan untuk prediksi jumlah kunjungan wisatawan nusantara dalam konteks wilayah Sulawesi Tenggara. Hasil penelitian diharapkan memberikan kontribusi bagi pengembangan sistem pendukung keputusan di bidang pariwisata berbasis *machine learning*.

HASIL DAN PEMBAHASAN

Penelitian ini menggunakan Google Colab sebagai lingkungan pengembangan untuk membangun dan mengevaluasi model prediksi LSTM dan SVR dalam meramalkan jumlah kunjungan wisatawan nusantara ke Sulawesi Tenggara. Proses pra-pemrosesan data dan pemodelan didukung oleh pustaka seperti TensorFlow, Keras, dan Scikit-learn. Sebelum dilakukan pemodelan, data deret waktu dinormalisasi dan diubah ke dalam format *supervised learning* dengan fitur *lag*. Model LSTM dilatih secara iteratif melalui proses *epoch*, dengan evaluasi metrik seperti *training loss* dan *validation loss* pada setiap iterasi. Sementara itu, model SVR dioptimalkan melalui pencarian grid untuk menentukan kombinasi *hyperparameter* terbaik. Evaluasi kinerja model dilakukan dengan menggunakan *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) berdasarkan data aktual tahun 2024 yang dijadikan *ground-truth* sebagai acuan pembandingan hasil prediksi.

Tabel 2. Hasil Perbandingan LSTM dan SVR

Kabupaten/Kota Tujuan	Jumlah Perjalanan Wisatawan Nusantara Menurut Kabupaten/Kota Tujuan (Perjalanan)										
	Data Aktual					Data Prediksi					
	2019	.	...	...	2024	2025		2026		2027	
	.	.	.	.	.	LST	SVR	LST	SVR	LST	SVR
						M		M		M	
Buton	16586	.	...	...	35813	35975	43134	37858	53251	38118	58619
	4	.			6	3	4	6	9	3	4
Muna	35078	.	...	...	62310	59214	90497	62939	14069	63412	16629
	7	.			5	1	6	7	60	8	47
Konawe	52903	.	...	...	13355	12042	14236	11326	16057	10737	16347
	4	.			44	21	18	26	71	86	27
Kolaka	52958	.	...	...	87784	81886	14003	82444	19938	82450	20596
	2	.			7	4	29	8	99	8	09
Konawe Selatan	60494	.	...	...	16085	14454	15281	14597	15727	14489	16065
	5	.			05	34	86	78	90	66	55
Bombana	28116	.	...	...	47517	50932	46746	53153	51160	52916	54281
	1	.			8	3	8	9	7	6	7
Wakatobi	11589	.	...	...	15136	51527	39349	73104	67912	72736	75833
	2	.			2	1	2	1	5	5	3
Kolaka Utara	28880	.	...	...	37226	32493	39635	31955	43528	31962	45177
	8	.			3	2	9	7	3	3	0
Buton Utara	72851	.	...	...	21853	31773	37589	38816	50366	39845	52848
	.	.			6	0	3	1	9	4	3
Konawe Utara	17493	.	...	...	62382	88407	51159	91805	43003	93576	39152
	4	.			3	6	8	1	6	4	1
Kolaka Timur	28504	.	...	...	49935	43408	88918	41115	12258	40777	12704
	4	.			3	4	3	4	82	1	54
Konawe Kepulauan	56192	.	...	...	14596	15371	15293	15624	15930	15646	16066
	.	.			8	6	7	2	6	6	9
Muna Barat	12512	.	...	...	29666	30538	28107	41423	33223	47202	37115
	8	.			2	6	6	4	5	1	1
Buton Tengah	14268	.	...	...	38039	35820	37463	36940	45806	36894	49719
	0	.			1	4	5	6	3	1	0
Buton Selatan	11146	.	...	...	29683	27128	35529	28794	47035	28955	51788
	5	.			1	4	2	0	6	1	6
Kota Kendari	15999	.	...	...	37303	38423	37798	38222	37691	37344	37677
	07	.			41	68	77	90	08	29	70


Kota Baubau	40712	.	...	...	..	95252	55563	97890	46171	10280	47375	10339
	3	.				8	1	0	2	15	6	65

Tabel 2 menyajikan jumlah perjalanan wisatawan nusantara menurut kabupaten atau kota tujuan dari tahun 2019 hingga 2027, dengan tahun 2019–2024 digunakan sebagai data aktual dan 2025–2027 sebagai hasil prediksi. Data aktual menunjukkan bahwa Kabupaten Buton memiliki jumlah perjalanan tertinggi pada tahun 2019 dengan 165.864 perjalanan, diikuti oleh Muna dan Konawe yang juga mencatat angka signifikan. Hasil prediksi menggunakan model LSTM dan SVR menunjukkan tren peningkatan pada sebagian besar wilayah, terutama di Kabupaten Konawe Selatan dan Kolaka yang diproyeksikan mengalami pertumbuhan pesat hingga tahun 2027. Meskipun terdapat fluktuasi di beberapa kabupaten, secara keseluruhan pola yang terbentuk menggambarkan potensi peningkatan mobilitas wisatawan nusantara yang dapat menjadi dasar penguatan strategi pengembangan pariwisata daerah.

Table 3. Hasil RMSE dan MAE Tahun 2024


Kabupaten/Kota Tujuan	LSTM		SVR	
	RMSE	MAE	RMSE	MAE
Buton	4838.23	3893.16	3447.69	3242.55
Muna	16450.01	11244.64	13607.56	12526.67
Konawe	18264.39	13511.53	28208.89	25613.19
Kolaka	11229.17	7997.02	17569.36	16843.71
Konawe Selatan	19523.9	15721.59	6315.29	4808.49
Bombana	7842.49	5345.02	2580.38	2088.1
Wakatobi	10099.59	9271.81	9242.95	9119.35
Kolaka Utara	3437.24	2910.62	1607.33	1531.22
Buton Utara	4350.27	3967.43	5814.21	5687.34
Konawe Utara	6621.88	5415.91	4614.48	3400.21
Kolaka Timur	7823.47	5160.5	13583.9	13498.78
Konawe Kepulauan	2521.39	2268.99	1102.42	765.09
Muna Barat	6648.21	5660.53	2302.54	2183.58
Buton Tengah	11134.06	6643.07	3468.67	2782.21
Buton Selatan	5744.45	3813.03	939.26	3741.54
Kota Kendari	71738.5	64995.3	138629.3	136947.3
Kota Baubau	16227.82	13148.82	6051.15	4375.4

Berdasarkan hasil evaluasi pada Tabel 3, model Support Vector Regression (SVR) secara konsisten menunjukkan kinerja yang lebih unggul dibandingkan model Long Short-Term Memory (LSTM) untuk prediksi data tahun 2024. Keunggulan ini terbukti dari nilai Root Mean Square Error (RMSE) dan Mean Absolute Error (MAE) yang lebih rendah pada 13 dari 17 kabupaten/kota yang diuji. Performa superior SVR paling signifikan terlihat pada prediksi untuk Kabupaten Konawe Selatan (RMSE 6315.29) dan Kota Baubau (RMSE 6051.15), di mana tingkat kesalahannya jauh lebih kecil dibandingkan LSTM. Meskipun demikian, model LSTM menunjukkan hasil yang lebih baik pada beberapa wilayah spesifik seperti Kabupaten Konawe dan Kota Kendari. Namun, secara keseluruhan, temuan ini mengindikasikan bahwa model SVR memiliki akurasi dan keandalan yang lebih tinggi untuk studi kasus prediksi ini.



Gambar 3. Grafik Prediksi perbandingan LSTM dan SVR (a) Buton (b) Muna (c) Konawe (d) Kolaka


Gambar 3 menyajikan perbandingan visual hasil prediksi jumlah kunjungan wisatawan antara model LSTM dan SVR di empat kabupaten: Buton (a), Muna (b), Konawe (c), dan Kolaka (d). Dari keempat grafik, terlihat perbedaan fundamental dalam proyeksi jangka panjang (2025-2027) yang dihasilkan oleh kedua model. Model LSTM (garis putus-putus ungu) secara konsisten memprediksi tren kenaikan yang signifikan, yang tampaknya menafsirkan lonjakan data pascapandemi sebagai awal dari pola pertumbuhan baru. Sebaliknya, model SVR (garis putus-putus merah) memberikan prediksi yang jauh lebih konservatif dengan menunjukkan tren yang cenderung stabil atau mendatar, mengindikasikan bahwa model ini menganggap lonjakan data historis tersebut sebagai sebuah anomali dan memproyeksikan kondisi akan kembali ke tingkat yang lebih stabil.



Gambar 4. Grafik Prediksi Kolaka (e) Konawe Selatan (f) Bombana (g) Wakatobi (h) Kolaka Utara


Gambar 4 melanjutkan perbandingan visual antara model LSTM dan SVR untuk empat wilayah berikutnya: Konawe Selatan (e), Bombana (f), Wakatobi (g), dan Kolaka Utara (h). Pola yang konsisten dari gambar sebelumnya kembali terlihat jelas, di mana model LSTM (garis putus-putus ungu) secara konsisten memproyeksikan tren pertumbuhan jumlah wisatawan untuk periode 2025-2027. Proyeksi ini terlihat sangat optimis, terutama pada grafik Wakatobi (g) yang menunjukkan potensi lonjakan tajam. Sebaliknya, model SVR (garis putus-putus merah) sekali lagi menawarkan prediksi yang jauh

lebih konservatif, dengan tren yang cenderung datar atau hanya menunjukkan kenaikan yang sangat landai. Perbedaan ini menegaskan bahwa LSTM lebih sensitif terhadap tren pemulihan terkini sebagai sinyal pertumbuhan berkelanjutan, sementara SVR menginterpretasikannya sebagai bagian dari fluktuasi yang akan kembali stabil di masa depan.



Gambar 5 Grafik Prediksi perbandingan LSTM dan SVR (i) Buton Utara (j) Konawe Utara (k) Kolaka timur (l) Konawe Kepulauan

Gambar 5 menampilkan perbandingan prediksi LSTM dan SVR untuk wilayah Buton Utara (i), Konawe Utara (j), Kolaka Timur (k), dan Konawe Kepulauan (l). Pola yang telah teridentifikasi sebelumnya sebagian besar berlanjut, di mana model LSTM (garis ungu) cenderung memproyeksikan tren pertumbuhan yang optimis untuk periode 2025-2027, sedangkan SVR (garis merah) umumnya memberikan prediksi yang lebih konservatif dan stabil. Namun, terdapat pengecualian yang menarik pada grafik Konawe Utara (j), di mana SVR justru memprediksi tren pemulihan naik yang signifikan, sementara LSTM memproyeksikan tren menurun. Kasus unik ini menyoroti bahwa meskipun ada kecenderungan umum, sensitivitas kedua model terhadap pola data historis dapat menghasilkan proyeksi jangka panjang yang sangat berbeda, bahkan berlawanan, pada wilayah-wilayah tertentu.



Gambar 6. Grafik Prediksi (m) Muna Barat (n) Buton Tengah (o) Buton Selatan (p) Kendari (q) Baubau

Gambar ini menyajikan seri perbandingan terakhir antara model LSTM dan SVR untuk wilayah Muna Barat (m), Buton Tengah (n), Buton Selatan (o), Kota Kendari (p), dan Kota Baubau (q). Meskipun model SVR (garis merah) secara konsisten mempertahankan proyeksi jangka panjang yang stabil dan konservatif di kelima grafik, perilaku model LSTM (garis ungu) menunjukkan variasi yang lebih besar. Pada beberapa kabupaten seperti Muna Barat (m), LSTM memprediksi tren menurun yang kontras dengan SVR. Namun, perbedaan paling dramatis terlihat pada data perkotaan yang lebih volatil di Kota Kendari (p) dan Kota Baubau (q). Di kedua kota tersebut, LSTM memproyeksikan pola yang berfluktuasi dan tidak stabil, sementara SVR merespons dengan prediksi penurunan tajam menuju level yang lebih rendah dan stabil. Grafik-grafik ini secara efektif menyoroti bagaimana SVR cenderung mengabaikan volatilitas ekstrem untuk prediksi jangka panjang yang datar, sedangkan LSTM mencoba menangkap dinamika kompleks tersebut, yang terkadang menghasilkan proyeksi yang tidak menentu.

Tabel 3. Perbandingan Penelitian

Judul Penelitian	Peneliti	Objek Penelitian	Metode	Hasil
Boosting wind turbine performance with advanced smart power prediction: Employing a hybrid ARMA-LSTM technique	Abdel-Haleem Abdel-Aty et al., 2024	Peramalan daya turbin angin	Model hibrida ARMA-LSTM + Discrete Wavelet Transform (DWT)	Akurasi 99,24%, meningkat 3,74% dibandingkan metode sebelumnya
Energy consumption prediction and optimization of industrial robots based on LSTM	Pei Jiang et al., 2024	Konsumsi energi robot industri (KUKA KR60-3, 6 DOF)	LSTM + Algoritma Genetika Adaptif	MAPE < 4,21%, pengurangan konsumsi energi sebesar 22,35%
Multi-branch LSTM encoded latent features with CNN-LSTM for Youtube popularity prediction	Neeti Sangwan, Vishal Bhatnagar, 2024	Popularitas video YouTube	Multi-branch LSTM (child-parent) untuk ekstraksi fitur laten + CNN-LSTM	Penurunan MAE sebesar 50%, peningkatan R ² sebesar 0,61% dibandingkan LR, SVR, FCN-LSTM
Forecasting Energy Consumption of a Public Building Using Transformer and Support Vector Regression	Junhui Huang, Sakdirat Kaewunruen, 2023	Konsumsi energi gedung perpustakaan universitas	Transformer + Support Vector Regression (SVR)	SVR menghasilkan R ² = 0,92 (lebih unggul dari Transformer dengan R ² = 0,82), sensitif terhadap input mendekati output
Penelitian Ini	Kariyamin, Sri Faslia Hamka, La Ode Alyandi, Egi Dio Bagus Sudewo, 2025	Jumlah kunjungan wisatawan domestik di Sulawesi Tenggara (17 kabupaten/kota)	LSTM vs SVR	SVR menunjukkan akurasi lebih tinggi dibandingkan LSTM dalam memprediksi pola musiman.

Penelitian ini berfokus pada peramalan jumlah kunjungan wisatawan domestik ke Sulawesi Tenggara dengan membandingkan performa LSTM dan SVR, menunjukkan keunggulan SVR dalam menangkap pola musiman dan fluktuasi pascapandemi secara lebih akurat. Temuan ini sejalan dengan tren penggunaan model deep learning dalam prediksi deret waktu seperti yang ditunjukkan oleh Pei Jiang et al. (2024), yang menggunakan LSTM untuk mengoptimalkan konsumsi energi robot industri dengan hasil MAPE < 4,21%. Selain itu, pendekatan hibrida sebagaimana digunakan oleh Abdel-Haleem Abdel-Aty et al. (2024) melalui kombinasi ARMA-LSTM juga menunjukkan peningkatan akurasi signifikan sebesar 3,74%. Sementara itu, penggunaan CNN-LSTM oleh Sangwan dan Bhatnagar (2024) untuk prediksi popularitas video di YouTube mempertegas keunggulan LSTM dalam menangkap fitur laten yang kompleks. Dibandingkan dengan pendekatan SVR seperti dalam studi Huang dan Kaewunruen (2023), penelitian ini menunjukkan bahwa meskipun LSTM cukup kompetitif, model berbasis SVR lebih unggul dalam konteks data yang memiliki dinamika musiman dan nonlinier, seperti yang terdapat dalam sektor pariwisata.

KESIMPULAN

Berdasarkan hasil perbandingan yang dilakukan, penelitian ini menyimpulkan bahwa model Support Vector Regression (SVR) secara umum menunjukkan akurasi yang lebih tinggi dibandingkan Long Short-Term Memory (LSTM) untuk memprediksi kunjungan wisatawan. Temuan ini didasarkan pada nilai RMSE dan MAE yang secara konsisten lebih rendah pada mayoritas besar kabupaten/kota yang diuji, yang mengindikasikan tingkat kesalahan prediksi yang lebih kecil. Meskipun LSTM menunjukkan kinerja unggul di beberapa wilayah spesifik, SVR terbukti lebih andal dan efektif secara keseluruhan untuk dataset ini. Inovasi penelitian ini terletak pada perbandingan empiris antara model berbasis *deep learning* (LSTM) dan model *machine learning* konvensional (SVR) dalam konteks peramalan kunjungan wisatawan di tingkat regional. Peluang pengembangan penelitian di masa depan sangat terbuka, khususnya melalui eksplorasi model hibrida yang menggabungkan kekuatan representasi temporal LSTM dengan kemampuan generalisasi SVR. Selain itu, integrasi data eksternal seperti kondisi ekonomi, kebijakan transportasi, dan *event* pariwisata dapat meningkatkan akurasi. Dengan pendekatan tersebut, sistem prediksi yang dihasilkan diharapkan mampu mendukung perencanaan strategis pariwisata daerah secara lebih adaptif dan berbasis bukti.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Direktorat Riset, Teknologi, dan Pengabdian kepada Masyarakat (DRTPM-DIKTI), Kemdiktisaintek RI atas dukungan pendanaan penelitian skema PDP melalui kontrak dengan LLDIKTI Wilayah IX Nomor: 130/C3/DT.05.00/PL/2025 tanggal 28 Mei 2025 serta kontrak antara LLDIKTI IX dan Institut Teknologi dan Bisnis Muhammadiyah Wakatobi Nomor: 599/LL9/PG/2025 tanggal 3 Juni 2025, dan juga kepada Institut Teknologi dan Bisnis Muhammadiyah Wakatobi melalui LPPM Nomor: 35/Lppm/ITBMW/2025 atas dukungan dan fasilitas yang diberikan selama pelaksanaan penelitian ini.

DAFTAR PUSTAKA

- Abdel-Aty, A. H., Nisar, K. S., Alharbi, W. R., Owyed, S., & Alsharif, M. H. (2024). Boosting Wind Turbine Performance With Advanced Smart Power Prediction: Employing A Hybrid ARMA-LSTM Technique. *Alexandria Engineering Journal*, 96, 58–71. <https://doi.org/10.1016/j.aej.2024.03.078>
- Afrianto, M. A., & Wasesa, M. (2022). The Impact Of Tree-Based Machine Learning Models, Length Of Training Data, And Quarantine Search Query On Tourist Arrival Prediction's Accuracy Under COVID-19 In Indonesia. *Current Issues in Tourism*, 25(23), 3854–3870. <https://doi.org/10.1080/13683500.2022.2085079>

- Avenali, A., Catalano, G., D'Alfonso, T., & Matteucci, G. (2020). The Allocation Of National Public Resources In The Italian Local Public Bus Transport Sector. *Research In Transportation Economics*, 81, 100822. <https://doi.org/10.1016/J.RETREC.2020.100822>
- BPS. (2024). Statistik Wisatawan Nusantara 2023. In *Badan Pusat Statistik*
- Chen, Y., Yang, J., Zhang, K., Xu, Y., & Liu, Y. (2021). A Feature-Cascaded Correntropy LSTM for Tourists Prediction. *IEEE Access*, 99, 32810–32822. <https://doi.org/10.1109/ACCESS.2021.3059943>
- Christy, J., & Umamakeswari, A. (2020). Performance Enhancement of Outlier Removal Using Extreme Value Analysis-Based Mahalonobis Distance. *IGI Global*, 14. <https://doi.org/10.4018/978-1-7998-2491-6.ch014>
- Dary, D., Winata, A., Kumara, S., & Suhartono, D. (2021). Predicting Stock Market Prices Using Time Series SARIMA. *Proceedings of 2021 1st International Conference on Computer Science and Artificial Intelligence*, 24, 92–99. <https://doi.org/10.1109/ICCSAI53272.2021.9609720>
- Hanafiah, N., Setiawan, Y., Buntaran, A., & Reynaldi, M. (2022). Sentiment Analysis of Tourism Objects on Trip Advisor Using LSTM Method. *Journal of Computer Science and Technology Studies*, 4(2), 01–06. <https://doi.org/10.32996/jcsts.2022.4.2.1>
- He, H., Gao, S., Jin, T., Sato, S., & Zhang, X. (2021). A Seasonal-Trend Decomposition-Based Dendritic Neuron Model For Financial Time Series Prediction. *Applied Soft Computing*, 108, 107488. <https://doi.org/10.1016/j.asoc.2021.107488>
- Huang, J., & Kaewunruen, S. (2023). Forecasting Energy Consumption of a Public Building Using Transformer and Support Vector Regression. *Energies*, 16(2). <https://doi.org/10.3390/en16020966>
- Jiang, P., Wang, Z., Li, X., Wang, X. V., Yang, B., & Zheng, J. (2023). Energy Consumption Prediction And Optimization Of Industrial Robots Based On LSTM. *Journal of Manufacturing Systems*, 70, 137–148. <https://doi.org/10.1016/j.jmsy.2023.07.009>
- Khaira, U., Putri, M. F., & Yanova, S. (2025). Peramalan Kadar PM 10 Menggunakan Algoritma Long Short-Term Memory (LSTM) Sebagai Acuan Ketersediaan Ruang Terbuka Hijau Di Kota Jambi. *Decode*, 5(1), 289–302. <https://doi.org/http://dx.doi.org/10.51454/decode.v5i1.866>
- Li, J., Lv, P., Li, H., & Chen, W. (2022). Outlier Detection Based on Stacked Autoencoder and Gaussian Mixture Model. *IEEE International Conference on Big Data (Big Data)*, 3763–3769. <https://doi.org/10.1109/BigData55660.2022.10020738>
- Lima, M. A. F. B., Ramírez, L. M. F., Carvalho, P. C. M., Batista, J. G., & Freitas, D. M. (2021). A Comparison Between Deep Learning and Support Vector Regression Techniques Applied to Solar Forecast in Spain. *Journal of Solar Energy Engineering*, 144(1). <https://doi.org/10.1115/1.4051949>
- Lin, B., Ghaddar, B., & Nathwani, J. (2022). Deep Reinforcement Learning for the Electric Vehicle Routing Problem With Time Windows. *IEEE Transactions on Intelligent Transportation Systems*, 23(8), 11528–11538. <https://doi.org/10.1109/TITS.2021.3105232>
- Ma, K., & Leung, H. (2019). A Novel LSTM Approach for Asynchronous Multivariate Time Series Prediction. In *International Joint Conference on Neural Network (IJCNN)*, 30. <https://doi.org/10.1109/IJCNN.2019.8851792>
- Madhulika, P. S. S., & Sampath, N. (2022). An Application of Normalizer Free Neural Networks on the SVHN Dataset. *International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, 238–242. <https://doi.org/10.1109/ICAAIC53929.2022.9793301>
- Passalis, N., Tefas, A., Kannianen, J., Gabbouj, M., & Iosifidis, A. (2020). Deep Adaptive Input Normalization for Time Series Forecasting. *IEEE Transactions on Neural Networks and Learning Systems*, 31(9), 3760–3765. <https://doi.org/10.1109/TNNLS.2019.2944933>

- Pawar, P., Gonjari, S., Kshirsagar, S., & Chhajed, D. G. J. (2024). A Review of Linear Regression and Support Vector Regression. *Interantional Journal Of Scientific Research In Engineering And Management*, 08(12), 1–9. <https://doi.org/10.55041/IJSREM40400>
- Proietti, T., Marczak, M., & Mazzi, G. (2019). A Class Of Periodic Trend Models For Seasonal Time Series. *Journal Of Forecasting*, 38(2), 106–121. <https://doi.org/10.1002/for.2562>
- Salem, M., & Khalil, M. G. (2022). The Support Vector Regression Model: A New Improvement For Some Data Reduction Methods With Application. *Pakistan Journal of Statistics and Operation Research*, 18(2), 427–435. <https://doi.org/10.18187/pjsor.v18i2.4049>
- Sangwan, N., & Bhatnagar, V. (2025). Multi-Branch LSTM Encoded Latent Features With CNN-LSTM For Youtube Popularity Prediction. *Scientific Reports*, 15(1), 2508. <https://doi.org/10.1038/s41598-025-86785-3>
- Shuhua, C., Yuan, G., Desheng, L., Yi, S., & Di, W. (2023). Tourism Analytics Before and After COVID-19. *Springer Nature Singapore*, 119–137. https://doi.org/10.1007/978-981-19-9369-5_8
- Sun, Y., Hao, J., Sun, Z., & Liu, D. (2025). Analyzing the Construction of Prediction Models Based on LSTM Machine Learning. *International Conference on Electronics and Communication, Network and Computer Technology (ECNCT)*, 622–625. <https://doi.org/10.1109/ECNCT66493.2025.11172642>
- UNWTO. (2024). *International Tourism Highlights, 2024 Edition*. UN Tourism. <https://doi.org/10.18111/9789284425808>
- Zhu, F., Gao, J., Xu, C., Yang, J., & Tao, D. (2018). On Selecting Effective Patterns for Fast Support Vector Regression Training. *IEEE Transactions on Neural Networks*, 3610 – 3622. <https://doi.org/10.1109/TNNLS.2017.2734812>
- Zulkifli Noor, Z. (2022). Creating Tourism Sector Opportunities In The Time Of The Covid-19 Pandemic. *Sosiohumaniora*, 24(2), 272–280. <https://doi.org/10.24198/sosiohumaniora.v24i2.38522>