



JURNAL SISTEM INFORMASI DAN TEKNOLOGI (S I N T E K)

Situs Jurnal

<https://sintek.stmikku.ac.id/index.php/home>

HYBRID DEEP LEARNING UNTUK PREDIKSI KUNJUNGAN TAMU HOTEL

Azral Satrani^{*1}, Bambang Krismono², Khasnur Hidjah³

^{1,2,3} Program Studi Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Bumigora Mataram
Jl. Ismail Marzuki, No. 22 Cakranegara, Mataram, Telepon : 085936159725

Email: ¹azral@universitasbumigora.ac.id, ²bkrismono@universitasbumigora.ac.id,
³khasnur72.h@universitasbumigora.ac.id

ABSTRAK

Prediksi jumlah kunjungan tamu hotel adalah aspek penting dalam pengelolaan operasional dan perencanaan strategis, terutama pasca pandemi Covid-19 yang menyebabkan fluktuasi tinggi dalam kunjungan. Holiday Resort Lombok, resort bintang empat di Senggigi, mencatat pertumbuhan kunjungan 35,20% dari 2022 hingga 2023, menunjukkan pemulihan pariwisata. Penelitian ini mengembangkan model prediksi menggunakan *hybrid deep learning* yang mengintegrasikan *Convolutional Neural Network* (CNN) untuk mengekstraksi pola spasial dan *Long Short-Term Memory* (LSTM) untuk menangani aspek temporal. Dataset terdiri dari 730 catatan harian kunjungan dari Januari 2022 hingga Desember 2023, dengan pelatihan model pada variasi epoch (50, 100, 150, dan 200). Hasil terbaik diperoleh pada 150 epoch, dengan *Root Mean Square Error* (RMSE) 29,55 untuk data pelatihan dan 32,23 untuk data pengujian, menunjukkan akurasi yang lebih baik dibandingkan metode tradisional. Namun, model menunjukkan potensi overfitting, memerlukan optimalisasi lebih lanjut. Model ini dapat mendukung pengambilan keputusan terkait alokasi sumber daya dan strategi pemasaran. Penelitian selanjutnya disarankan untuk mengeksplorasi ensemble learning dan integrasi variabel eksternal untuk meningkatkan ketepatan model.

Kata Kunci: *Prediksi Kunjungan Tamu, Hybrid Deep Learning, CNN, LSTM, Hotel*

1. PENDAHULUAN

Holiday Resort Lombok merupakan Resort bintang empat terletak di Senggigi, Lombok. Resort ini menghadap ke Selat Lombok memiliki banyak jenis kamar, seperti *Garden Chalet Room* (STD), *Ocean View Room* (OCV), *Beach Bungalow Room* (BGW), *Two Bedrom Mangsit Suite* (TBR), *Beach Garden Suite* (BGS) dan *Grand Ocean View* (GOV) dengan kolam renang pribadi yang memiliki total keseluruhan kamar 188 kamar.

Pasca pandemi Covid-19 industri perhotelan menghadapi tantangan besar dalam memprediksi jumlah pengunjung dengan akurat, terutama karena fluktuasi yang signifikan dalam pola kunjungan [1]. Hal ini dapat dibuktikan dengan adanya peningkatan jumlah kunjungan wisatawan yang datang ke Provinsi Nusa Tenggara Barat, baik dari wisatawan dalam negeri maupun luar negeri pada tahun 2022, hasilnya tercatat pada situs pemerintah data.ntbprov.go.id mengalami kenaikan sebesar

42.78%. Holiday Resort Lombok sendiri mengalami peningkatan kunjungan dari tahun 2022 sampai 2023 dengan kenaikan sebesar 35,20% yang dapat dibuktikan dari jumlah kunjungan tamu dan penyewaan kamar yang ada di histori aplikasi hotel.

Penting bagi manajemen dan operasional Holiday Resort Lombok untuk memastikan bahwa jumlah kunjungan tamu yang akan datang terus meningkat. Dengan mengetahui jumlah kunjungan tamu dengan melakukan prediksi diharapkan manajemen dan operasional Holiday Resort Lombok dapat merencanakan kebutuhan staf, persediaan, dan layanan lainnya berjalan lancar. Selain itu pemahaman pola kunjungan memungkinkan manajemen merancang strategi pemasaran yang lebih efektif, memaksimalkan pengelolaan pendapatan untuk keberlanjutan bisnis [2].

Prediksi merupakan suatu metode yang kuat untuk menganalisis data dengan tujuan memprediksi peristiwa di masa depan. Metode ini sering

digunakan oleh para ahli bisnis berdasarkan sejarah data. Ada beberapa cara untuk membuat prediksi yang akurat. Saat ini perkembangan *Machine Learning* (ML) dan *Deep Learning* (DL) semakin meningkat seiring dengan kemajuan di bidang ilmu komputer

Pada penelitian [3] metode *Deep Learning* mampu memecahkan masalah kompleks dengan tingkat kesalahan yang rendah. Salah satu kelebihan dari *deep learning* yang menjadikan nilai tambah dibandingkan menggunakan *machine learning* adalah *deep learning* mampu mengolah data dalam jumlah yang sangat besar.

Convolutional Neural Network (CNN) merupakan pengembangan dari *Artificial Neural Network* (ANN) konvensional. CNN memiliki arsitektur *network* terdiri dari puluhan hingga ratusan layer. CNN dibandingkan dengan metode *deep learning* lainnya memiliki kemampuan lebih diterapkan pada data *supervised*, data augmentasi dan memiliki kemampuan *feature learning* lebih baik [4].

Namun salah satu hal yang harus diperhatikan adalah bahwa satu metode atau algoritma tidak selalu dapat menyelesaikan masalah riil, terkadang kita harus menyelesaikan masalah dengan menggabungkan atau mengkombinasikan berbagai jenis metode atau algoritma. *Long Short Term Memory* (LSTM) merupakan jenis jaringan saraf tiruan yang sering digunakan untuk melakukan prediksi dalam ilmu meteorologi, analisa saham, ekonomi dan bisnis serta bidang ilmu lainnya.

LSTM mewakili kemajuan dalam pengembangan jaringan saraf yang khusus dirancang untuk memodelkan data time series. Keunggulan utama LSTM terletak pada kapasitasnya untuk menangani ketergantungan jangka panjang dalam data yang diinputkan ke dalamnya. LSTM juga memiliki blok memori yang memungkinkan identifikasi nilai mana yang dianggap paling relevan sebagai output berdasarkan input yang diterima. Aspek ini menjadi salah satu kelebihan signifikan dari penggunaan LSTM.

2. LANDASAN TEORI

2.1. Penelitian Terdahulu

Penelitian ini memberikan penekanan khusus untuk prediksi kunjungan tamu hotel yang belum banyak dijadikan objek kajian dalam penerapan *deep learning*. Penelitian yang dilakukan oleh [5] dengan judul “Prediksi jumlah tamu hotel di Provinsi NTB dengan metode Monte Carlo”. Prediksi jumlah kunjungan tamu menggunakan metode Monte Carlo menghasilkan jumlah tamu hotel di NTB tahun 2025 akan mengalami fluktuasi sepanjang tahun.

Penelitian oleh [6] berjudul “Prediksi Jumlah Menginap di Hotel Karlita International, Tegal, Jawa Tengah”. Penelitian ini dilakukan prediksi jumlah tamu yang menginap di Hotel Karlita Internatioanal dengan 11 metode. Dengan hasil penelitian bahwa metode Additive Decomposition-Average All memberikan prediksi terbaik. Penelitian yang pernah dilakukan [7] dengan judul “Peramalan Jumlah Tamu dan Pengunjung Dinner Hotel Mega Bintang Sweet Kabupaten Blora Dengan Pendekatan ARIMA”. Dengan hasil penelitian menunjukkan bahwa model *Autoregressive Integrated Moving Average* (ARIMA). Dengan hasil penelitian menunjukkan bahwa model ARIMA (0,1,1) adalah model terbaik dengan *Mean Squared Error* (MSE) terkecil sebesar 7754. Pada penelitian yang berjudul “Analisis Forecasting Jumlah Kunjungan Tamu Hotel di Kota Bukittinggi” dengan metode jaringan saraf tiruan (*artificial neural network*) dan *backpropagation*. *Artificial Neural Network* (ANN) mampu melakukan forecasting dengan tingkat akurasi yang tinggi. Dengan tingkat akurasi 99.98% dan tingkat kesalahan (*error*) 0.002%. Dan penelitian yang dilakukan [8] dengan judul “Peramalan Jumlah Tamu di Hotel “X” dengan pendekatan *Autoregressive Integrated Moving Average* (ARIMA), Fungsi Transfer dan *Adaptive Neuro Fuzzy Inference System* (ANFIS) digunakan untuk meningkatkan perencanaan manajemen dalam bisnis perhotelan.

2.2. Prediksi

Prediksi merupakan suatu metode yang kuat untuk menganalisis data dengan tujuan memprediksi peristiwa di masa depan. Metode ini sering digunakan oleh para ahli *business intelligence* untuk memahami kondisi bisnis berdasarkan sejarah data. Tujuan utama dari prediksi adalah untuk memprediksi hasil di masa depan, bukan perilaku data saat ini. Model prediksi membuat perkiraan tentang nilai data yang tidak dikenal dengan menggunakan nilai yang diidentifikasi [5].

2.3. Tamu Hotel

Tamu hotel di definisikan sebagai orang-orang yang ingin mendapat jasa layanan berkualitas yang ditawarkan oleh sebuah hotel [11].

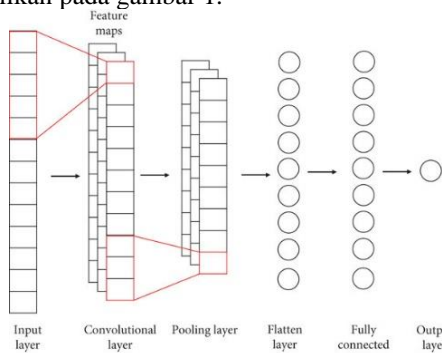
2.4. Deep Learning

Deep Learning adalah cabang dari pembelajaran mesin yang memanfaatkan jaringan saraf tiruan berlapis-lapis untuk memodel dan memahami pola kompleks dalam data. Teknik ini telah diterapkan secara luas dalam berbagai bidang,

termasuk pengenalan gambar, pemrosesan bahasa alami, dan analisis data deret waktu.

2.5. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan perkembangan lebih lanjut dari MLP (Multilayer Perceptron). Secara umum terdapat dua buah layer pada CNN, yaitu *feature extraction layer* dan *fully connected layer* (sitasi). *Feature extraction layer* terletak setelah *input layer*. *Feature extraction layer* disusun oleh dua jenis layer, yaitu *convolutional layer* dan *pooling layer* [12]. Dalam berbagai penelitian, metode CNN banyak digunakan untuk mengolah data berupa citra atau gambar menggunakan 2D *convolutional layer*. Di samping itu, metode CNN juga bisa digunakan untuk mengolah data berupa vektor seperti sinyal serta data *time series* menggunakan 1D *convolutional layer* [13] yang ditampilkan pada gambar 1.



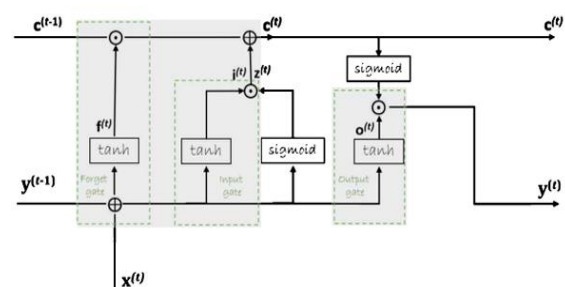
Gambar 1 Arsitektur umum CNN 1D

Gambar 1 diatas menggambarkan arsitektur Convolutional Neural Network (CNN) 1D yang terdiri dari beberapa lapisan yakni input ayer menerima data masukan seperti urutan angka atau teks. Convolutional layer digunakan menerapkan operasi konvolusi untuk mengekstrak fitur penting dari data. Pada pooling layer berguna mengurangi dimensi feature maps untuk mengurangi parameter dan menghindari overfitting. Lapisan flatten layer mengubah data multi-dimensi menjadi vektor satu dimensi. Fully connected layer menghubungkan semua neuron untuk menggabungkan informasi dan membuat keputusan serta hasil yang diinginkan. Output Layer memberikan hasil akhir, biasanya dengan fungsi aktivasi seperti softmax untuk klasifikasi. Secara keseluruhan, arsitektur gambar CNN 1D dirancang untuk mengekstrak fitur dari data sekuensial dan membuat prediksi.

2.6. Long Short Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan salah satu metode dalam Deep Learning yang dapat digunakan untuk Natural Language Processing (NLP) seperti pengenalan suara, translasi teks, dan juga analisis sentimen. LSTM merupakan pengembangan dari metode Recurrent Neural

Network (RNN), metode LSTM ini dibuat untuk menyelesaikan permasalahan vanishing gradient yang ada pada RNN [14].



Gambar 2 Arsitektur LSTM

Berikut penjelasan gambar 2 elemen-elemen pada arsitektur LSTM diatas

1. Block input : Unit ini, diberi label $Z^{(t)}$ adalah node yang mengambil adalah node yang mengambil aktivasi dengan cara standar dari lapisan input $X^{(t)}$ pada langkah waktu saat ini (sepanjang recurrent edges) dari hidden layer pada langkah waktu sebelumnya $y^{(t-1)}$. Biasanya masukkan memiliki bobot yang selanjutnya dijumlahkan kemudian melalui fungsi aktviiasi tanh.

$$z^t = \tanh(W_z x^t + R_z y^{t-1} + b_z)$$

2. Gerbang Gerbang Input: Gerbang input (Input gate), diberi label $i^{(t)}$ yang merupakan ciri khas dari LSTM. Gerbang adalah unit simoidal seperti halnya input node, mengambil aktivasi dari langkah data saat ini x^t serta dari hidden layer pada langkah sebelumnya. Unit ini disebut gerbang karena nilainya digunakan untuk mengalikan nilai node lain. Gerbang sigmodial ini jika nilainya nol, maka lairan dari node lain terputus. Jika nilai gerbang adalah satu, semua aliran dilewatkan.

$$i^t = \text{sigmoid}(W_i x^t + R_i y^{t-1} + p_i \odot c^{t-1} + b_i)$$

3. Gerbang lupa (Forget gate): Gerbang lupa menyediakan metode berupa jaringan yang dapat belajar untuk menyiram isi keadaan internal. Hal ini sangat berguan dalam daringan yang terus berjalan. Dengan gerbang lupa, persamaan untuk menghitung keadaan internal pada linstasan maju adalah :

$$f^{(t)} = \text{sigmoid}(W_f x^t + R_f y^{t-1} + p_{i_f} \odot c^{t-1} + b_f)$$

4. Cell state: Di jantung setiap sel memori terdapat node $C^{(t)}$ dengan aktivasi linier. Keadaan internal $c^{(t)}$ memiliki recurrent edge yang terhubung sendiri dengan bobot satuan tetap. Karena edge ini mencakup langkah waktu yang berdekatan dengan bobot konstan, gradien dapat mengalir melintasi langkah waktu tanpa menghilang atau menjadi sangat besar nilainya. Edge ini sering disebut korsel kesalahan konstanta (constant error carousel).

Dalam notasi vektor, pembaruan untuk keadaan internal adalah :

$$c^t = z^t \odot i^t + c^{t-1} \odot f^t$$

5. Gerbang Output: Langkah ini menghitung gerbang output yang menggabungkan masukkan arus $x^{(t)}$, keluaran dari unit LSTM $y^{(t-1)}$ dan nilai sel $c^{(t-1)}$ pada iterasi terakhir. Ini dapat dilakukan seperti pada persamaan.

$$o^t = \text{sigmoid}(W_o x^t + R_o y^{t-1} + p_o \odot c^{t-1} + b_o)$$

6. Output Block: Merupakan kombinasi *current cell value* dengan *current output get value* sebagaimana persamaan berikut :

$$y^t = \tanh(c^t) \odot o^t$$

Pada langkah diatas, sigmoid digunakan sebagai fungsi aktivasi gerbang, sedangkan tangen hiperbolik tanh sering digunakan sebagai fungsi aktivasi blok input dan output. Dalam persamaan diatas W, R dan p adalah bobot yang terkait $x^{(t)}, y^{(t-1)}$ dengan dan $c^{(t-1)}$ sedangkan b mewakili bobot bias.

2.7. Deret Waktu (Time Series)

Deret waktu atau *time series* merupakan sekumpulan data atau informasi yang terkumpul secara berkala atau dalam interval waktu tertentu. Deret waktu adalah suatu rangkaian observasi yang tercatat pada interval waktu yang teratur, seringkali dalam waktu singkat seperti jam, hari, atau minggu (sitasi).

2.8. Hybrid Deep Learning

Hybrid Deep Learning adalah kombinasi dari beberapa metode deep learning untuk meningkatkan kinerja sistem cerdas. Metode *hybrid* menggabungkan dua atau lebih algoritma *machine learning* atau *deep learning* untuk kinerja yang lebih tinggi dan hasil yang optimal. Pada penelitian ini menggunakan kombinasi deep learning

2.9. Dataset

Pada penelitian ini penulis menggunakan dataset primer tamu hotel yang penulis dapatkan dari pihak hotel periode awal tahun 2022 sampai akhir 2023. Dataset tamu hotel yang diberikan terdiri dari informasi seperti nama tamu, nomor resi, kedatangan, keberangkatan, kategori kamar dan nomor kamar.


2.10. Prediksi Deret Waktu

Permalan deret waktu adalah teknik memprediksi peristiwa melalui urutan waktu. Prediksi peristiwa masa depan dengan menganalisis tren masa lalu menggunakan asumsi bahwa tren masa depan akan terus mirip dengan tren historis.

Asumsi ini digunakan di banyak bidang studi (sitasi) dalam berbagai bidang seperti astronomi, perencanaan bisnis, teknik kontrol, prediksi gempa, statistik dan lain sebagainya.

3. METODE PENELITIAN

Tahapan penelitian menjelaskan proses yang dilakukan dalam penelitian ini, adapun tahapan penelitian dimulai dari pengumpulan data, pemrosesan data, implemnetasi model, pengujian model dan hasil evaluasi. Alur tahapan penelitian dapat dilihat pada gambar 3.



Gambar 3 Alur Penelitian

3.1. Pengumpulan Data

Dalam tahapan ini, dilakukan pengumpulan data dari Holiday Resort Lombok yang berupa data kunjungan tamu dari awal tahun 2022 hingga tahun 2023 akhir dengan jumlah 730 data. Data yang terkumpul merupakan jenis data time-series, yang ditampilkan pada bentuk tabel berikut.

Tabel 1. Data

ResNo	Arrival	Depart	Categ	RmNo
67292	22/01/2022	23/01/2022	STD	561
68371	14/01/2022	16/01/2022	STD	539
68371	14/01/2022	16/01/2022	STD	545
68540	12/01/2022	14/01/2022	STD	406
68540	12/01/2022	14/01/2022	STD	404
.....
77474	18/01/2023	21/01/2023	OVC	312
77520	13/01/2023	15/01/2023	STD	424
76902	27/01/2023	29/01/2023	OVC	322
76001	21/01/2023	22/01/2023	STD	525
78694	26/01/2023	27/01/2023	OVC	302

Pada tabel 1 diatas ditampilkan data mentah kunjungan tamu hotel yang, memberikan informasi mengenai pola kedatangan tamu, durasi menginap, dan penggunaan kamar. Data ini dapat membantu dalam perencanaan kapasitas dan strategi pemasaran hotel.

3.2. Preprocessing Data

Preprocessing data atau pra pemrosesan data, adalah serangkaian langkah atau tahapan yang dilakukan pada data mentah sebelum data tersebut digunakan untuk dianalisis lebih lanjut atau pengembangan model. Dalam pengolahan data awal, proses awal adalah memasukkan nilai tengah, atau media, dari keseluruhan data untuk melengkapi nilai yang hilang atau tidak ada. Setelah mengatasi missing value, dilakukan tahapan reduksi dimensi untuk mengurasing jumlah atribut atau fitur dalam data untuk mengurangi kompleksitas dan mempercepat analisis. Data yang digunakan pada penelitian ini memiliki rentang nilai yang jauh antara nilai minimum dan nilai maksimum pada jumlah tamu harian. Berikut hasil dari preprocessing data yang direpresentasikan dalam bentuk tabel sebagai berikut.

Tabel 2 hasil preprocessing data

No	Tanggal	Jumlah Tamu
1	01/01/2022	174
2	02/01/2022	32
3	03/01/2022	13
4	04/01/2022	24
5	05/01/2022	15
..
726	27/12/2023	38
727	28/12/2023	29
728	29/12/2023	59
729	30/12/2023	17
730	31/12/2023	4

Data yang akan diolah untuk memprediksi jumlah kedatangan tamu harian untuk waktu yang akan datang disajikan dalam tabel 2. Data yang digunakan adalah data csv yang berisi nomor, tanggal, dan jumlah tamu.

3.3. Prediksi Hybrid Deep Learning

Pada penelitian ini akan mengembangkan model deep learning untuk memprediksi kunjungan tamu hotel. Untuk melakukannya, CNN akan digunakan untuk mengekstraksi pola dari data historis kunjungan tamu, dan LSTM akan digunakan

untuk mengumpulkan pola temporal dan jangka panjang dalam fluktuasi kunjungan tamu.

3.4. Pengujian Akurasi

Pengujian dilatih menggunakan set pelatihan, pengujian dilakukan untuk menilai kinerja prediksi. Setelah model diberikan data historis kunjungan tamu yang tidak digunakan untuk pelatihan, nilai prediksi dan aktual dibandingkan.

3.5. Evaluasi Model

Pada tahapan evaluasi model penelitian ini menggunakan Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE) digunakan sebagai evaluasi performa model yang dibangun. Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE) merupakan evaluasi kinerja yang sering digunakan untuk algoritma prediksi. Mean Absolute Error (MAE) digunakan untuk mengukur besarnya rata-rata kesalahan dalam serangkaian prediksi, tanpa mempertimbangkan arahnya. Ini adalah rata dari sampel uji tentang perbedaan mutlak antara prediksi dan pengamatan aktual dimana semua perbedaan individu memiliki bobot yang sama.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - X_i|$$

Diketahui :

- n : jumlah data
- X_i : nilai kebenaran dasar
- Y_i : nilai predksi

Selain menggunakan evaluasi Mean Absolute Error (MAE) penelitian ini juga menggunakan Root Mean Square Error (RMSE) untuk melakukan evaluasi model. Root Mean Square Error (RMSE) akar kuadrat dari MSE, penggunaan RMSE sangat penting dalam penelitian karena memberikan gambaran yang jelas tentang kinerja model dalam konteks unit yang relevan.

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (Y_j - \hat{Y}_j)^2}$$

Diketahui :

- Y_j : nilai observasi sampel matriks Y
- \hat{Y}_j : nilai prediksi dari model regresi
- n : jumlah data


Root Mean Square Error (RMSE) mengukur seberapa jauh nilai yang diprediksi oleh model dari nilai aktual. Metrik ini dihitung dengan mengambil akar kuadrat dari rata-rata kuadrat selisih antara nilai yang diprediksi dan nilai aktual.

4. HASIL DAN PEMBAHASAN

Pada penelitian menggunakan model CNN dan LSTM untuk mengambil pola dari data time-series yang meliputi


1. Layer convolutional 1D digunakan untuk mengekstrak bentuk spasial lokal dari urutan kunjungan
2. Layer Maxpooling untuk mengurangi fitur hasil konvolusi.
3. Dua lapisan LSTM bermanfaat untuk menangkap pola temporal jangka panjang
4. Layer output yang memprediksi harga penutupan kunjungan adalah dense layer.

4.1. Hasil Prediksi Model Hybrid Deep Learning




Gambar 4 Perbandingan jumlah tamu data asli dan prediksi dengan epoch 50

Gambar 4 memaparkan perbandingan antara data aktual dengan data hasil prediksi yang dihasilkan oleh model dengan menggunakan epoch 50. Model mampu memberikan prediksi antara data aktual dan data prediksi dengan nilai *train RMSE*: 30.58 *test RMSE* : 35.55.




Gambar 5. Perbandingan jumlah tamu data asli dan prediksi dengan epoch 100

Gambar 5 memaparkan perbandingan antara data aktual dengan data hasil prediksi yang dihasilkan oleh model dengan menggunakan epoch 100. Model mampu memberikan prediksi antara data aktual dan data prediksi dengan nilai *Train RMSE*: 29.84, *test RMSE* : 33.27.



Gambar 6 Perbandingan jumlah tamu data asli dan prediksi dengan epoch 150

Gambar 6 menampilkan perbandingan antara data aktual dengan data hasil prediksi yang dihasilkan oleh model dengan menggunakan epoch 100. Model mampu memberikan prediksi antara data aktual dan data prediksi dengan nilai *train RMSE*: 29.85, *test RMSE* : 32.23.



Gambar 7 Perbandingan jumlah tamu data asli dan prediksi dengan epoch 200

Gambar 7 menampilkan perbandingan antara data aktual dengan data hasil prediksi yang dihasilkan oleh model dengan menggunakan epoch 100. Model mampu memberikan prediksi antara data aktual dan data prediksi dengan nilai *train RMSE*: 29.55, *test RMSE* : 32.47.

Dari hasil analisa grafik perbandingan jumlah tamu yang ditampilkan dengan epoch 50,100,150 dan 200 dapat penggunaan epoch 150 dengan metode hybrid deep learning CNN dan LSTM memiliki nilai RMSE terendah dibandingkan dengan epoch 50, 100 dan 200.

4.2. Hasil Prediksi

Dalam upaya meningkatkan layanan dan membantu manajemen hotel dalam memprediksi banyaknya kunjungan tamu hotel dengan menerapkan algoritma *hybrid deep learning*. Tabel 3 menampilkan prediksi kunjungan tamu hotel dalam jangka 30 hari kedepan.

Tanggal	Hasil prediksi
01/01/2024	65
02/01/2024	61
03/01/2024	62
.....	...
12/01/2024	58
13/01/2024	58
14/01/2024	57
15/01/2024	57
16/01/2024	56
.....
28/01/2024	43
29/01/2024	43
30/01/2024	43

5. PENUTUP

5.1. Kesimpulan dan Saran

Seperti yang ditampilkan pada penelitian ini, *hybrid deep learning* CNN dan LSTM dapat memberikan prediksi kunjungan tamu yang cukup akurat. Dengan pengujian yang dilakukan pada tiga skenario epoch (50, 100 dan 150), pengaturan epoch 150 memiliki RMSE terendah nilai *train RMSE*: 29.55, *test RMSE* : 32.47. tetapi dengan *overfitting*. Model prediksi ini akurat dalam menangkap pola aktual dari data historis. Penelitian menunjukkan *hybrid deep learning* mungkin lebih dari pada teknik prediksi konvensional. Untuk meningkatkan akurasi model prediksi dalam skenario kunjungan tamu hotel penelitian mendatang harus mencoba model yang lebih kompleks dan jumlah data yang lebih banyak.

DAFTAR PUSTAKA

- [1] B. Zhang, N. Li, R. Law, and H. Liu, "A hybrid MIDAS approach for forecasting hotel demand using large panels of search data," *Tourism Economics*, vol. 28, no. 7, pp. 1823–1847, Nov. 2022, doi: 10.1177/13548166211015515.
- [2] N. Dowlut and B. Gobin-Rahimbux, "Forecasting resort hotel tourism demand using deep learning techniques – A systematic literature review," *Heliyon*, vol. 9, no. 7, Jul. 2023, doi: 10.1016/j.heliyon.2023.e18385.
- [3] A. Cecaj, M. Lippi, M. Mamei, and F. Zambonelli, "Comparing deep learning and statistical methods in forecasting crowd distribution from aggregated mobile phone data," *Applied Sciences (Switzerland)*, vol. 10, no. 18, Sep. 2020, doi: 10.3390/APP10186580.
- [4] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, "Deep Learning for Computer Vision: A Brief Review," 2018, *Hindawi Limited*. doi: 10.1155/2018/7068349.
- [5] Y. S. Pasaribu, J. William, I. V. Ps, K. Baru, K. Percut, and S. Tuan, "Prediksi Jumlah Tamu Hotel di Provinsi NTB dengan Metode Monte Carlo," *Jurnal Penelitian dan Karya Ilmiah*, vol. 2, no. 3, 2024, doi: 10.59059/mutiara.v2i2.1326.
- [6] H. Sarjono and I. Zulkifli, "PREDIKSI JUMLAH TAMU MENGINAP DI HOTEL KARLITA INTERNATIONAL, TEGAL, JAWA TENGAH." *Seminar Nasional Edusainstek*. 2018.
- [7] J. Sains and D. Seni Pomits, "Peramalan Jumlah Tamu di Hotel 'X' dengan Pendekatan Arima, Fungsi Transfer, dan Anfis," 2013.
- [8] W. Damayanti, D. Yulianto, A. 3bsi, Y. Yogyakarta'jl, G. Ringroad Barat Ambarketawang, and Y. Sleman, "PERANAN HOUSEKEEPING DALAM MENANGANI KOMPLAIN UNTUK MEMBERIKAN KEPUASAN TAMU DI MAWAR ASRI HOTEL JOGJA," 2014.
- [9] I. Gede, I. Sudipa, and M. Darmawiguna, "BUKU AJAR DATA MINING," 2024. [Online]. Available: <https://www.researchgate.net/publication/377415198>
- [10] K. Nungqi Somala, R. Dwi Respati, and R. K. Hera Merdeka, "PENGARUH KUALITAS PELAYANAN TERHADAP LOYALITAS TAMU HOTEL NOVOTEL." [Online]. Available: https://jurnal.umt.ac.id/public/journals/40/homepageImage_en_US.jpg
- [11] A. Agga, A. Abbou, M. Labbadi, and Y. el Houm, "Short-term self consumption PV plant power production forecasts based on hybrid CNN-LSTM, ConvLSTM models," *Renew Energy*, vol. 177, May 2021, doi: 10.1016/j.renene.2021.05.095.
- [12] P. A. Bayupati, A. A. A. S. Dewi, and N. K. A. Wirdiani, "Perbandingan Metode Artificial Neural Network dan Artificial

Neural Network untuk Memprediksi Jumlah Distribusi Air di PDAM Kota Denpasar,” *JST (Jurnal Sains dan Teknologi)*, vol. 12, no. 2, Oct. 2023, doi: 10.23887/jstundiksha.v12i2.47800.

- [14] M. Z. Rahman, Y. A. Sari, and N. Yudistira, “Analisis Sentimen Tweet COVID-19 menggunakan Word Embedding dan Metode Long Short-Term Memory (LSTM),” 2021. [Online]. Available: <http://j-ptiik.ub.ac.id>