BAB II

TINJAUAN PUSTAKA

2.1. Studi Sebelumnya

Ampountalas melakukan penelitian untuk menangani tantangan dalam meramalkan permintaan harian hotel yang bersifat fluktuatif dan kompleks dengan membandingkan kinerja berbagai model statistik dan *machine learning*. Penelitian ini menggunakan dataset permintaan harian dari sebuah hotel di Boston selama periode 2015–2019, yang terdiri dari 1.484 observasi, dan membagi data menjadi set pelatihan dan pengujian. Selain data historis, penelitian ini mempertimbangkan variabel eksternal seperti suhu, hari libur nasional dan lokal, peringkat kompetitor, serta hari dalam minggu untuk meningkatkan kualitas prediksi. Model yang diuji meliputi Seasonal Naïve, Holt-Winters, ARIMA, SARIMAX, jaringan saraf tiruan multilayer perceptron (ANN-MLP), serta model volatilitas sGARCH dan GJR-GARCH. Evaluasi dilakukan menggunakan MAE, RMSE, dan MAPE, dengan tambahan ukuran relatif untuk ANN-MLP. Hasil menunjukkan bahwa SARIMAX menunjukkan kinerja terbaik pada sebagian besar horizon prediksi karena kemampuannya mengintegrasikan variabel eksternal, sementara model GARCH sangat tepat untuk menangkap volatilitas dan shock harian. ANN-MLP memberikan prediksi yang kompetitif untuk horizon pendek, namun kalah pada prediksi menengah dan panjang, sedangkan *Seasonal* Naïve memiliki akurasi paling rendah [9].

Pereira dan Cerqueira melakukan penelitian untuk membandingkan keakuratan 22 metode peramalan dalam memprediksi permintaan hotel jangka pendek hingga 14 hari guna mendukung sistem *Revenue Management*. Penelitian menggunakan data seri waktu harian dari sebuah Resort Yintang empat di Eropa Selatan selama 2011–2015, dengan pola musiman kompleks yang memerlukan transformasi varians, penghapusan tren dan musiman, serta penerapan model auto-regressive berbasis embedding waktu dengan jendela 30 hari. Metode yang diuji mencakup prosedur statistik tradisional seperti Naive, Holt-Winters, ARIMA,

double *seasonal* exponential smoothing, serta algoritma *machine learning* seperti Support Vector Regression, Random Forest, XGBoost, Generalized Boosted Regression, dan model ensemble berbasis metalearning (Arbitrated Dynamic Ensemble, ADE). Hasil penelitian menunjukkan bahwa metode *machine learning* lebih unggul dibanding metode statistik tradisional, dengan pengurangan RMSE hingga 54% untuk prediksi 1 hari dan 45% untuk prediksi 14 hari, khusus untuk prediksi jangka pendek (1–7 hari), model ensemble ADE menunjukkan kinerja terbaik dengan RMSE sekitar 9,30, sedangkan untuk prediksi 8–14 hari, model ML individual seperti Support Vector Regression dan Principal Components Regression menunjukkan performa lebih baik [14].

Henriques dan Pereira melakukan sebuah *systematic literature review* yang membahas penerapan metode berbasis kecerdasan buatan, *machine learning*, dan *deep learning* dalam peramalan *demand* hotel, manajemen pendapatan, serta prediksi okupansi dan pembatalan reservasi. Studi ini menganalisis sejumlah penelitian terpilih menggunakan kerangka PRISMA dengan sumber data dari Web of Science dan Scopus, yang mencakup penggunaan data historis reservasi, tingkat hunian, pembatalan, ulasan pelanggan, media sosial, cuaca, dan faktor eksternal lainnya. Hasil tinjauan menunjukkan bahwa model berbasis *machine learning* dan *deep learning* umumnya mampu menangkap pola non-linear dan interaksi kompleks antarvariabel, terutama pada peramalan jangka pendek dan data dengan pengaruh faktor eksternal yang kuat. Studi ini juga menyoroti bahwa keberhasilan penerapan teknologi ini sangat bergantung pada kualitas data, pemilihan model yang tepat, serta kemampuan hotel dalam mengelola dan mengadaptasi teknologi tersebut sesuai kebutuhan dan kondisi lokal [13].

Contessi dkk. mengembangkan model peramalan okupansi hotel yang tidak hanya akurat tetapi juga mudah diinterpretasikan oleh manajer hotel, untuk mengatasi keterbatasan model prediktif "*black-box*". Pendekatan yang digunakan terdiri dari dua langkah, yaitu reduksi dimensi data booking melalui *Principal Component Analysis* (PCA) untuk mengidentifikasi pola umum pada *booking curves*, dan penerapan metode pickup aditif berbasis jarak di ruang dimensi rendah tersebut untuk memprediksi permintaan di masa depan, dengan

penambahan variabel harga rata-rata harian (ADR) untuk meningkatkan akurasi prediksi. Hasil penelitian menunjukkan bahwa model berbasis PCA secara konsisten lebih unggul dibandingkan metode *benchmark* tradisional, termasuk pada periode pasca-pandemi COVID-19, serta terbukti tahan terhadap perubahan pola booking yang tidak menentu [11].

Viverit dkk. melakukan penelitian untuk meningkatkan akurasi peramalan permintaan kamar hotel pada kondisi pasar yang tidak stabil, khususnya setelah gangguan besar seperti pandemi COVID-19. Penelitian ini menggunakan data reservasi dari tiga hotel berbeda yang mencakup tanggal pemesanan, tanggal kedatangan, lama menginap, tarif kamar, dan jumlah kamar yang dipesan. Pendekatan yang diterapkan terdiri dari dua tahap. Tahap pertama mengelompokkan kurva pemesanan historis menggunakan algoritma *machine learning* untuk membentuk cluster berdasarkan pola perilaku pemesanan, sehingga setiap cluster mencerminkan karakteristik pemesanan yang berbeda. Tahap kedua menggunakan model *additive pickup* pada masing-masing cluster untuk memprediksi permintaan harian hingga delapan minggu ke depan. Hasil penelitian menunjukkan bahwa model berbasis cluster lebih akurat dibandingkan metode pickup tradisional, dengan peningkatan akurasi prediksi sebesar 8,5% pada horizon 14 hari dan 32,7% pada horizon 50 hari di salah satu hotel. Analisis juga menyoroti bahwa pengelompokan berdasarkan pola pemesanan mampu menangkap perubahan perilaku pelanggan yang terjadi selama pandemi, sehingga memberikan prediksi yang lebih andal pada kondisi pasar yang tidak pasti [15].

Penelitian-penelitian sebelumnya menekankan peramalan *demand* harian atau jangka pendek dengan pendekatan statistik dan *machine learning*, serta ada yang mengadopsi *deep learning* atau *clustering* untuk meningkatkan akurasi. Penelitian-penelitian sebelumnya lebih menitikberatkan pada perbandingan akurasi model *forecasting* tanpa memperhatikan karakteristik permintaan hotel dan belum terdapat pendekatan yang secara sistematis dapat menjelaskan keterkaitan antara karakteristik permintaan hotel dan pemilihan model peramalan permintaan secara efisien.

Tabel 2.1. Studi Sebelumnya

No	Peneliti	Tahun	Metode	Tujuan	Temuan
1	Ampountalas [9]	2021	SARIMA, SARIMAX, ANN-MLP, sGARCH, GJR-GARCH, Holt-Winters, *Seasonal* Naïve	Membandingkan kinerja berbagai model statistik dan *machine learning* dalam memprediksi permintaan harian hotel	SARIMAX memiliki MAPE terbaik pada sebagian besar horizon prediksi, GARCH efektif menangkap volatilitas, ANN-MLP kompetitif untuk horizon pendek, Seasonal Naïve paling rendah akurasinya
2	Henriques & Pereira [13]	2024	Literature Review	Mengkaji berbagai model dan metode peramalan permintaan dan tingkat hunian hotel berbasis statistik, *machine learning*, dan *deep learning*	Metode peramalan berbasis AI dapat meningkatkan akurasi prediksi dibandingkan metode statistik tradisional meskipun masih terdapat tantangan terkait standar data dan penerapan di berbagai jenis hotel dan wilayah
3	Contessi dkk [11]	2024	PCA + *Additive Pickup*	Mengembangkan model peramalan okupansi hotel yang akurat sekaligus mudah dipahami oleh manajer hotel	Model berbasis PCA secara konsisten lebih akurat dibanding metode pickup tradisional, prediksi lebih andal pada periode dengan okupansi tinggi, tambahan ADR meningkatkan keakuratan prediksi

No	Peneliti	Tahun	Metode	Tujuan	Temuan
4	Pereira & Cerqueira [14]	2022	Naive, Exponential Smoothing, ARIMA, Holt-Winters, Double Seasonal Exponential Smoothing, Support Vector Regression, Random Forest, XGBoost, Generalized Boosted Regression, Ensemble Metalearning (ADE)	Membandingkan keakuratan 22 metode peramalan untuk permintaan hotel jangka pendek hingga 14 hari untuk mendukung sistem *Revenue Management*	*Machine learning* unggul dibanding statistik tradisional, RMSE berkurang hingga 54% untuk prediksi 1 hari dan 45% untuk prediksi 14 hari. ADE terbaik untuk 1-7 hari, SVR dan PCR unggul untuk 8-14 hari
5	Viverit dkk [15]	2023	Clustering Kurva Booking + *Additive Pickup*	Meningkatkan akurasi peramalan permintaan kamar hotel pada kondisi pasar tidak stabil, khususnya pasca-pandemi COVID-19	Model berbasis cluster lebih akurat dibanding metode *pickup* tradisional, peningkatan akurasi 8,5% untuk horizon 14 hari dan 32,7% untuk horizon 50 hari, mampu menangkap perubahan perilaku pemesanan selama pandemi

2.2. Dasar Teori

2.2.1. Industri Perhotelan

Industri perhotelan merupakan bagian dari sektor pariwisata yang menyediakan layanan penginapan bagi wisatawan atau tamu dengan pengelolaan profesional dan berorientasi komersial. Hotel adalah istilah umum yang mencakup semua penginapan komersial yang menyediakan kamar untuk menginap serta fasilitas pendukung seperti layanan makan dan minum. Hotel berfungsi sebagai tempat tinggal sementara bagi wisatawan dengan standar operasional dan layanan yang profesional [16]. Hotel bisa dikategorikan ke dalam beberapa tipe berdasarkan fungsi, fasilitas, dan pengelolaannya, antara lain *guesthouse* dan *resort*. *Guesthouse*, sebagai salah satu tipe hotel, adalah penginapan berskala lebih kecil yang bisa berupa rumah biasa yang dikonversi atau dibangun khusus untuk akomodasi jangka pendek. Bentuknya dapat berupa apartemen wisata, rumah kecil, atau lodge lokal yang ditujukan untuk liburan atau tinggal sementara. *Guesthouse* menawarkan pengalaman menginap yang lebih personal dan fasilitas yang lebih sederhana dibanding hotel pada umumnya [17]. Sedangkan**,** *resort* merupakan tipe hotel yang menyediakan fasilitas khusus untuk kegiatan rekreasi dan olahraga, seperti tenis, golf, *spa*, *tracking*, dan *jogging*. *Resort* tidak hanya menyediakan penginapan, tetapi juga pengalaman rekreasi dan leisure yang terintegrasi di lokasi penginapan [18].

Karakteristik permintaan hotel berbeda tergantung tipe dan segmentasi pasar yang dilayani. Hotel domestik yang lebih banyak dikenal oleh masyarakat lokal dan berfungsi lebih fungsional, seperti tipe *guesthouse,* memiliki permintaannya relatif stabil, kurang sensitif terhadap fluktuasi musiman, dan memiliki elastisitas permintaan yang lebih rendah (inelastik). Sebaliknya, hotel yang melayani wisatawan *leisure*, seperti tipe *resort,* menunjukkan variasi permintaan yang lebih tinggi antara musim rendah dan tinggi, sensitif terhadap liburan, akhir pekan, dan event tertentu, sehingga permintaannya cenderung fluktuatif dan dipengaruhi perilaku konsumen leisure [19]. Perbandingan tipe hotel *guesthouse* dan *resort* bisa dilihat pada Tabel 2.2.

Tabel 2. 2 Perbandingan Tipe Hotel *Guesthouse* dan *Resort*

Tipe Hotel	Karakteristik	Karakteristik Permintaan
Guesthouse	Skala kecil, bisa berupa rumah biasa yang dikonversi atau dibangun khusus, fasilitas sederhana	Permintaan relatif stabil, kurang sensitif terhadap fluktuasi musiman, elastisitas rendah (inelastik), berorientasi kebutuhan fungsional, dikenal masyarakat lokal
Resort	Menyediakan fasilitas rekreasi dan olahraga (tenis, golf, spa, tracking, jogging), pengalaman leisure terintegrasi	Permintaan fluktuatif, sensitif musim liburan, akhir pekan, dan event; dipengaruhi perilaku konsumen leisure, variasi tinggi antara musim rendah dan tinggi

2.2.2. *Revenue Management*

Revenue Management (RM) merupakan pendekatan strategis dalam pengelolaan pendapatan yang bertujuan untuk mengoptimalkan pendapatan perusahaan melalui pengelolaan permintaan dan kapasitas yang tersedia. Pendekatan ini menekankan prinsip menjual produk yang tepat kepada pelanggan yang tepat, pada waktu yang tepat, dengan harga yang tepat, serta melalui saluran distribusi yang tepat [2]. Dalam penerapannya, RM memanfaatkan sistem informasi, analisis data, dan strategi penetapan harga untuk mengelola permintaan pelanggan dan memaksimalkan pemanfaatan sumber daya yang terbatas. Pada industri perhotelan, karakteristik seperti kapasitas yang mudah hilang (*perishability*), keterbatasan peningkatan kapasitas dalam jangka pendek, serta adanya segmentasi pasar menjadikan RM sangat penting dalam mendukung strategi

penetapan harga dan pengendalian kapasitas guna meningkatkan profitabilitas [20].

Dalam konteks tersebut, pemahaman terhadap pola permintaan menjadi krusial, salah satunya melalui konsep *booking curve* dan *lead time*. *Booking curve* merepresentasikan akumulasi pemesanan kamar sebagai deret waktu kumulatif hingga mendekati tanggal menginap, yang digunakan untuk memprediksi tingkat hunian berdasarkan data historis maupun data terkini. Sementara itu, *lead time* menggambarkan selang waktu antara saat pemesanan dilakukan dengan tanggal menginap, yang mencerminkan perilaku pelanggan dalam melakukan reservasi. Pola *booking curve* dan *lead time* dapat dipengaruhi oleh berbagai faktor, seperti musiman, harga, saluran distribusi, promosi, serta perkembangan teknologi yang memungkinkan pemesanan dilakukan secara fleksibel [21]. Analisis terhadap kedua konsep ini membantu dalam mengidentifikasi karakteristik permintaan, seperti kecenderungan *early booking* atau *last-minute booking*, sehingga dapat mendukung pengambilan keputusan terkait strategi harga, alokasi kapasitas, dan peningkatan akurasi peramalan dalam sistem *Revenue Management*.

2.2.3. *Revenue Management* System

Revenue Management System (RMS) adalah sistem teknologi berbasis data yang dirancang untuk mengoptimalkan pendapatan hotel melalui penyesuaian harga secara strategis sesuai kondisi pasar dan pengelolaan kapasitas yang terbatas. Sistem ini memanfaatkan algoritma dan analitik data untuk menganalisis data historis, tren pasar, perilaku konsumen, serta informasi kompetitor, sehingga dapat menghasilkan rekomendasi harga dan pengaturan ketersediaan kamar secara dinamis. Prinsip dasar RMS adalah mengombinasikan strategi penetapan harga dan pengendalian inventori berbasis data, memungkinkan hotel merespons perubahan permintaan secara proaktif dengan menaikkan harga pada periode permintaan tinggi dan menyesuaikan tarif pada periode permintaan rendah, sehingga kinerja pendapatan dan profitabilitas dapat dioptimalkan [22]. RMS

mengintegrasikan berbagai modul yang saling berkaitan, termasuk *price optimization, dynamic pricing, revenue forecasting*, dan *demand forecasting*, untuk mendukung pengambilan keputusan manajerial [1].

2.2.4. *Forecasting*

Peramalan merupakan seni dan ilmu yang digunakan untuk memprediksi kejadian di masa depan dengan memanfaatkan data historis yang diproyeksikan ke periode mendatang melalui model matematis atau kombinasi beberapa model yang sesuai [23]. Berdasarkan objek yang diramalkan, peramalan diklasifikasikan menjadi tiga jenis, yaitu peramalan ekonomi, peramalan teknologi, dan peramalan permintaan. Peramalan permintaan (*demand forecasting*) berfokus pada upaya memperkirakan jumlah produk atau layanan yang dibutuhkan pada periode mendatang agar organisasi dapat menyesuaikan kapasitas, persediaan, dan sumber daya secara optimal [24].

Berdasarkan pendekatan yang digunakan, peramalan dibedakan menjadi dua jenis utama, yaitu:

a. Peramalan kualitatif

   Peramalan kualitatif adalah peramalan yang didasarkan pada penilaian subjektif, pengalaman, serta keahlian pengambil keputusan. Pendekatan ini umumnya digunakan ketika data historis terbatas atau kondisi masa depan sulit diprediksi secara numerik.

b. Peramalan kuantitatif

   Peramalan kuantitatif adalah peramalan yang menggunakan metode statistik dan matematis untuk menganalisis pola pada data historis dan menghasilkan prediksi yang dapat diukur secara objektif [25].

Dalam konteks peramalan permintaan, pendekatan kuantitatif lebih banyak digunakan karena mampu memberikan hasil yang konsisten dan dapat dievaluasi secara empiris.

Salah satu pendekatan utama dalam peramalan kuantitatif adalah peramalan berbasis deret waktu (*time-series*). Model *time-series* memprediksi nilai masa depan berdasarkan pola yang terbentuk dari nilai

masa lalu suatu variabel serta kesalahan prediksi pada periode sebelumnya [26]. Pendekatan ini banyak digunakan karena mampu menangkap karakteristik data seperti tren dan musiman. Seiring berkembangnya teknologi, metode *time-series* tidak hanya dikembangkan melalui pendekatan statistik konvensional, tetapi juga melalui pendekatan berbasis *machine learning*. Metode statistik menawarkan keunggulan dalam interpretabilitas dan transparansi struktur model, sedangkan metode *machine learning* memiliki kemampuan yang lebih baik dalam menangkap pola nonlinier dan interaksi kompleks dalam data [27].

2.2.5. Algoritma Peramalan

Algoritma peramalan merupakan metode yang digunakan untuk membangun model prediksi berdasarkan pola yang terdapat pada data historis. Berbagai algoritma telah dikembangkan untuk memodelkan data deret waktu dengan karakteristik yang berbeda, baik melalui pendekatan statistik maupun berbasis *machine learning* dan *deep learning*. Setiap algoritma memiliki mekanisme pemodelan, asumsi, serta kemampuan yang berbeda dalam menangkap pola tren, musiman, maupun kompleksitas hubungan dalam data.

2.2.5.1. ARIMA

Model Autoregressive Integrated Moving Average (ARIMA) merupakan model peramalan deret waktu berbasis statistik yang mengembangkan model ARMA dengan menambahkan proses diferensiasi (*integration*) untuk menangani data non-stasioner. Model ARIMA didefinisikan oleh parameter (p, d, q), yang masing-masing merepresentasikan komponen *autoregressive* (AR-p), *integrated* (I-d), dan *moving average* (MA-q) [9]. Komponen AR memodelkan hubungan linear antara nilai saat ini dengan nilai sebelumnya, sedangkan komponen MA memodelkan hubungan dengan *error* pada periode sebelumnya. Komponen *differencing* digunakan untuk menghilangkan tren sehingga data menjadi stasioner. Dalam penerapannya, ARIMA memiliki kompleksitas

komputasi yang relatif rendah dan interpretabilitas yang baik. Namun, model ini mengandalkan asumsi linearitas sehingga memiliki keterbatasan dalam menangkap pola non-linear. ARIMA juga sensitif terhadap outlier serta memerlukan proses identifikasi orde model yang tepat agar menghasilkan performa yang optimal [28].

2.2.5.2. SARIMA

SARIMA adalah perluasan dari ARIMA yang menambahkan komponen musiman $(P, D, Q)_s$ dengan s menunjukkan periode musiman, sehingga mampu menangkap pola berulang pada periode tertentu. Model ini efektif dalam memodelkan data dengan fluktuasi musiman yang jelas, sehingga peramalan *demand* hotel dapat menjadi lebih akurat, namun tetap berbasis pada hubungan linear seperti ARIMA [9].

2.2.5.3. SARIMAX

SARIMAX adalah pengembangan SARIMA yang memasukkan variabel eksogen (*external regressors*). Model SARIMAX dinyatakan sebagai SARIMAX $(p, d, q) * (P, D, Q)_s$, di mana selain komponen non-musiman dan musiman, model ini juga mengintegrasikan variabel eksternal yang memengaruhi variabel target, seperti kalender, kondisi pasar, atau faktor lingkungan. Integrasi ini memungkinkan model menangkap dinamika data secara lebih komprehensif dibandingkan SARIMA konvensional [9].

2.2.5.4. Holt-Winters

Metode Holt-Winters (HW) merupakan metode peramalan deret waktu yang digunakan untuk data yang memiliki pola tren dan musiman, dengan menggabungkan tiga komponen utama yaitu level, tren, dan *seasonality*. Metode ini memiliki dua variasi, yaitu *additive* untuk pola musiman dengan amplitudo konstan dan *multiplicative* untuk pola musiman yang mengikuti perubahan level data. Karakteristik utama Holt-Winters adalah kemampuannya

menangkap tren dan musiman secara simultan melalui pendekatan smoothing yang adaptif berdasarkan pola historis data [29].

2.2.5.5. XGBoost

XGBoost (Extreme Gradient Boosting) adalah algoritma *machine learning* berbasis *ensemble* yang dikembangkan dari metode *gradient boosting* untuk meningkatkan kinerja prediksi melalui proses pembelajaran model secara bertahap. Metode ini bekerja dengan membangun model secara berurutan, di mana setiap model baru dilatih untuk memperbaiki kesalahan dari model sebelumnya dengan meminimalkan fungsi kerugian (*loss function*). XGBoost umumnya menggunakan *decision tree* sebagai model dasar karena kemampuannya dalam memodelkan hubungan nonlinier pada data. Selain itu, algoritma ini dilengkapi dengan mekanisme regularisasi dan strategi optimasi berbasis gradien yang memanfaatkan informasi gradien orde pertama dan kedua dari fungsi kerugian, serta menyediakan berbagai pengaturan hyperparameter seperti *learning rate*, jumlah iterasi, dan kedalaman pohon untuk mengontrol kompleksitas model. Dengan karakteristik tersebut, XGBoost banyak digunakan dalam berbagai studi prediksi, termasuk pada peramalan data deret waktu [30].

2.2.5.6. LSTM

Model Long Short-Term Memory (LSTM) merupakan salah satu arsitektur dari Recurrent Neural Network (RNN) yang dirancang untuk memodelkan data berurutan atau deret waktu dengan mempertimbangkan informasi dari waktu sebelumnya. LSTM dikembangkan untuk mengatasi permasalahan *vanishing gradient* pada RNN melalui mekanisme memori khusus berupa *memory cell* dan tiga komponen utama (*input gate*, *forget gate*, dan *output gate*) yang mengatur aliran informasi. Melalui mekanisme tersebut, LSTM mampu menangkap dependensi jangka panjang dalam data secara

lebih efektif, sehingga banyak digunakan dalam berbagai permasalahan prediksi dan peramalan deret waktu [31].

2.2.6. Akurasi Model

Evaluasi akurasi model merupakan tahap penting dalam proses peramalan untuk menilai sejauh mana hasil prediksi yang dihasilkan oleh suatu model mendekati nilai aktual. Pengukuran akurasi umumnya dilakukan dengan menggunakan berbagai metrik kesalahan (*error metrics*) yang menggambarkan besarnya perbedaan antara nilai hasil peramalan dan data sebenarnya. Beberapa metrik yang umum digunakan dalam evaluasi model peramalan antara lain *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) [32].

2.2.6.1. MAE

MAE mengukur rata-rata besarnya kesalahan prediksi dalam satuan yang sama dengan data asli. Nilai ini diperoleh dari rata-rata selisih absolut antara nilai aktual dan nilai hasil peramalan. MAE memberikan gambaran kesalahan model secara langsung tanpa memperbesar pengaruh error yang sangat besar. Nilai MAE yang lebih rendah menunjukkan tingkat akurasi model yang lebih baik karena prediksi berada lebih dekat dengan data aktual.

2.2.6.2. RMSE

RMSE merupakan akar kuadrat dari rata-rata kuadrat selisih antara nilai aktual dan prediksi. Karena kesalahan dikuadratkan terlebih dahulu, metrik ini lebih sensitif terhadap error yang besar sehingga mampu menunjukkan apakah model menghasilkan deviasi yang signifikan. Nilai RMSE yang lebih kecil menandakan bahwa prediksi model semakin mendekati data sebenarnya sehingga performa model dianggap lebih baik.

2.2.6.3. MAPE

MAPE menyatakan besarnya kesalahan dalam bentuk persentase terhadap nilai aktual. Metrik ini memudahkan

interpretasi karena menunjukkan seberapa besar kesalahan prediksi secara relatif.

2.2.7. *Computational Time*

Waktu komputasi mengacu pada durasi yang dibutuhkan oleh suatu algoritma untuk menyelesaikan tugas komputasi [33]. Dalam konteks peramalan, tugas komputasi tersebut meliputi proses pemrosesan data, pelatihan model, hingga menghasilkan prediksi. Perbedaan metode yang digunakan dapat memengaruhi kompleksitas perhitungan dan kebutuhan sumber daya komputasi.

2.2.8. Tabel Pembanding

Tabel 2.3. Perbandingan Model *Forecasting*

Metode	Kategori	Kebutuhan Data	Sensitivitas Outlier	Kompleksitas Komputasi	Kemampuan Nonlinier
ARIMA	Statistik	Rendah – Sedang	Sensitif	Rendah	Terbatas
SARIMA	Statistik	Rendah – Sedang	Sensitif	Rendah	Terbatas
SARIMAX	Statistik	Sedang	Sensitif	Sedang	Terbatas
Holt-Winters	Statistik	Rendah	Sensitif	Rendah	Terbatas
XGBoost	*Machine learning*	Sedang – Tinggi	*Robust*	Sedang	Sangat Baik
LSTM	*Deep learning*	Tinggi	Sensitif	Tinggi	Sangat Baik

Penelitian ini menggunakan enam model forecasting sebagai kandidat utama, yaitu ARIMA, SARIMA, SARIMAX, Holt-Winters, XGBoost, dan LSTM. Pemilihan model-model ini didasarkan pada literatur sebelumnya dan karakteristik umum data *time series* pada hotel. Model statistik klasik seperti ARIMA dan Holt-Winters dipilih karena sederhana, interpretatif, dan efektif untuk data dengan pola stabil. SARIMA dan SARIMAX dipilih untuk menangkap pola musiman, dengan SARIMAX menambahkan kemampuan variabel eksogen seperti hari libur. XGBoost dipilih

karena kemampuannya menangkap hubungan non-linear dan adaptif terhadap fluktuasi. LSTM dipilih untuk mengeksplorasi kemampuan *deep learning* dalam mempelajari pola *sequence* yang lebih kompleks. Dengan kombinasi model statistik, *machine learning*, dan *deep learning*, penelitian ini dapat mengevaluasi performa *forecasting* secara komprehensif dan menjadi dasar pemetaan model berdasarkan karakteristik *demand.*