

Comprehensive Framework for Optimizing Demand Forecasting Implementation: A Bibliometric Analysis

[Kerangka Kerja Komprehensif untuk Optimalisasi Implementasi Peramalan Permintaan: Analisis Bibliometrik]

Rifkiansyah Aryasatya Pramudita ¹⁾, Rita Ambarwati Sukmono ^{*,2)}

¹⁾ Program Studi Magister Manajemen, Universitas Muhammadiyah Sidoarjo, Indonesia

²⁾ Program Studi Magister Manajemen, Universitas Muhammadiyah Sidoarjo, Indonesia

*Email Penulis Korespondensi: ritaambarwati@umsida.ac.id

Abstract. *Geopolitical uncertainty, supply chain disruptions, and dynamic market conditions underscore the critical role of demand forecasting in modern business strategy. The results of accurate demand forecasting enable organizations to anticipate customer demand, perform optimal inventory management, improve supply chain efficiency and also make strategic decisions based on data. Forecasting models have currently experienced quite rapid development along with the integration of technologies such as machine learning and deep learning which are able to overcome the limitations of traditional forecasting models in processing complex and nonlinear data. Integration of technology into demand forecasting models has been proven to improve the accuracy and adaptability of forecasting models, but there are still challenges in its implementation related to data quality, selection of appropriate forecasting models and availability of computing resources. This study uses mixed method by conducting bibliometric analysis on 502 documents and content analysis on 144 relevant documents from the Scopus database. The purpose of this study is to identify research trends, literature gaps, and global collaborations in demand forecasting model development and to formulate a comprehensive framework to optimize demand forecasting implementation. The results of this study indicate increasing trend in the use of hybrid forecasting models that combine traditional forecasting models with machine learning or deep learning. This study also proposes comprehensive framework that can be used to optimize the implementation of demand forecasting with the aim of improving forecast accuracy and strengthening the organization's ability to anticipate dynamic and uncertain global market environment.*

Keywords - *Bibliometric Analysis; Demand Forecasting; Deep Learning; Machine Learning; Supply Chain Optimization*

Abstrak. *Ketidakpastian geopolitik, gangguan rantai pasok, dan kondisi pasar yang dinamis menjadikan peramalan permintaan memiliki peran yang penting dalam strategi bisnis modern. Hasil dari peramalan permintaan yang akurat, memungkinkan organisasi untuk dapat mengantisipasi permintaan pelanggan, melakukan manajemen persediaan dengan optimal, meningkatkan efisiensi rantai pasok dan juga pengambilan keputusan strategis berbasis data. Model peramalan pada saat ini telah mengalami perkembangan yang cukup pesat seiring dengan pengintegrasian teknologi seperti machine learning dan juga deep learning yang mampu menutupi keterbatasan model peramalan tradisional dalam memproses data yang kompleks dan bersifat nonlinier. Pengintegrasian teknologi dalam model peramalan permintaan telah terbukti dapat meningkatkan akurasi dan adaptabilitas model peramalan, namun masih terdapat tantangan dalam implementasinya terkait dengan kualitas data, pemilihan model peramalan yang sesuai dan ketersediaan sumber daya komputasi. Penelitian ini menggunakan metode campuran dengan melakukan analisis bibliometrik pada 502 dokumen dan analisis konten pada 144 dokumen relevan yang telah memenuhi kriteria inklusi dari database Scopus. Tujuan dari penelitian ini adalah untuk mengidentifikasi tren penelitian, kesenjangan literatur, dan kolaborasi global dalam pengembangan model peramalan permintaan dan untuk merumuskan kerangka kerja komprehensif guna mengoptimalkan implementasi peramalan permintaan. Hasil dari penelitian ini menunjukan adanya tren peningkatan dalam penggunaan model peramalan hibrida yang menggabungkan antara model peramalan tradisional dengan machine learning atau deep learning. Penelitian ini juga mengusulkan kerangka kerja komprehensif yang dapat digunakan untuk mengoptimalkan implementasi peramalan permintaan dengan tujuan untuk meningkatkan akurasi peramalan serta memperkuat kemampuan organisasi dalam mengantisipasi lingkungan pasar global yang dinamis dan tidak pasti.*

Kata Kunci - *Analisis Bibliometrik; Peramalan Permintaan; Machine Learning; Deep Learning; Optimasi Rantai Pasok*

I. PENDAHULUAN

Ketidakpastian ekonomi global pada saat ini dipengaruhi oleh berbagai faktor yang saling berkaitan satu sama lain. Konflik geopolitik merupakan salah satu faktor yang menjadi penyebab gangguan utama pada perdagangan internasional dan stabilitas pasar. Rantai pasok global yang tidak kunjung stabil sejak pandemi, berdampak pada ketersediaan barang dan harga barang. Situasi ini diperburuk dengan fluktuasi harga energi yang mempengaruhi biaya produksi dan transportasi. Selain itu, inflasi yang terjadi diberbagai negara berakibat pada menurunnya daya beli masyarakat. Dalam menghadapi ketidakstabilan ekonomi, peramalan menjadi alat yang sangat penting untuk meramalkan permintaan dan mengelola sumber daya secara efektif [1]. Selain itu peramalan juga dapat digunakan sebagai alat dalam memitigasi dampak dari perubahan permintaan pasar yang fluktuatif melalui pendekatan berbasis data [2]. Situasi ini menjadikan peramalan semakin diakui sebagai salah satu komponen penting dalam perencanaan strategi bisnis untuk mendukung pengambilan keputusan yang lebih baik dalam menghadapi risiko dan peluang.

Peramalan, adalah proses sistematis untuk memproyeksikan atau memprediksi kejadian, nilai atau tren di masa depan berdasarkan pada data historis dan informasi yang berkaitan dengan subjek yang diramalkan dengan teknik analisis yang terstruktur. Penerapan peramalan bertujuan untuk mengurangi resiko ketidakpastian yang diakibatkan oleh faktor internal maupun eksternal dan memberikan panduan bagi pengambilan keputusan untuk menyusun rencana yang strategis. Armstrong (2001) mendefinisikan bahwa peramalan adalah proses yang mengintegrasikan pendekatan kuantitatif melalui analisis statistik dengan pendekatan kualitatif seperti penilaian para ahli untuk dapat menghasilkan prediksi yang akurat dan dapat dipercaya [3]. Sementara itu Hyndman dan Athanasopoulos (2018) mendefinisikan peramalan sebagai sebuah metode analisis yang digunakan untuk mengenali pola serta keterkaitannya didalam data untuk memperkirakan kondisi atau hasil pada masa yang akan datang [4].

Penggunaan model peramalan tradisional mendominasi pada masa awal perkembangannya. Model tradisional memiliki titik berat pada analisis data masa lalu untuk mengenali pola data sebagai dasar dalam memprediksi tren atau kondisi dimasa depan. Model peramalan tradisional seperti regresi linier, analisis deret waktu (*time series*), *exponential smoothing*, dan ARIMA (*Autoregressive Integrated Moving Average*) menjadi model yang paling populer dan paling sering digunakan. Model peramalan tradisional dirancang untuk data yang memiliki pola stabil dan struktur yang linier. Sebagai contoh adalah model ARIMA yang menggabungkan tiga elemen utama dalam peramalan yaitu autoregresi, pengintegrasian data, dan rata-rata bergerak, menjadikannya alat yang kuat untuk memproyeksikan tren musiman dan non - musiman dalam berbagai aplikasi pada berbagai sektor industri [5]. Keunggulan model peramalan tradisional adalah interpretasinya yang tinggi. Model peramalan dengan interpretabilitas tinggi memudahkan pemahaman dasar dari prediksi yang dihasilkan, sehingga meningkatkan kepercayaan terhadap hasil peramalan. Selain itu, interpretabilitas yang tinggi memungkinkan identifikasi anomali atau kesalahan dalam model peramalan melalui penjelasan komponen-komponen yang berbeda. Struktur sederhana dari model peramalan tradisional juga membuatnya lebih transparan [4]. Namun, sejalan dengan peningkatan kompleksitas data, model tradisional mulai menunjukkan berbagai keterbatasan, khususnya dalam mengolah data yang memiliki pola nonlinier serta tingkat ketidakpastian yang tinggi. Model tradisional sering sekali kurang mampu dalam menganalisis maupun mengidentifikasi data modern yang memiliki sifat dinamis dan tidak terstruktur. [6]. Meskipun model peramalan tradisional berperan sebagai fondasi awal, adanya tuntutan akan adanya model peramalan yang lebih fleksibel dan canggih telah mendorong munculnya pengembangan model-model peramalan baru yang lebih adaptif untuk mengolah karakteristik data yang semakin kompleks.

Sejalan dengan perkembangan teknologi informasi yang semakin pesat dan semakin melimpahnya ketersediaan *big data*, *machine learning* berkembang menjadi komponen penting dalam pengembangan peramalan. Penggunaan *machine learning* seperti *Neural Networks*, *Random Forest*, dan *Support Vector Machines (SVM)* dalam peramalan memungkinkan adanya proses analisis data yang lebih mendalam dan presisi sekaligus memberikan kemampuan untuk mengolah data yang memiliki sifat kompleks dan pola non-linear, yang sulit diidentifikasi oleh model peramalan tradisional [7]. *Machine learning* menawarkan fleksibilitas yang lebih tinggi dalam menangkap pola data yang dinamis dan menghasilkan prediksi dengan akurasi yang lebih tinggi dibandingkan dengan model tradisional, terutama dalam skenario yang melibatkan data multivariat atau data dengan *noise* yang tinggi [8]. Dalam beberapa tahun terakhir, terjadi perkembangan yang signifikan dengan munculnya model hibrida dalam peramalan. Pengembangan model hibrida dalam peramalan bertujuan untuk meningkatkan akurasi dan keandalan peramalan melalui proses kombinasi dari berbagai model peramalan serta mengatasi keterbatasan metode tunggal, sehingga mampu menangkap pola data yang lebih kompleks dan beragam [9]. Model hibrida mengintegrasikan beberapa model peramalan untuk memanfaatkan keunggulan dan mengatasi kelemahan yang ada dari masing-masing model peramalan. Kombinasi ini memungkinkan hasil yang lebih akurat karena masing-masing model memberikan kelebihan unik yang tidak dimiliki oleh model lainnya [10]. Model hibrida dalam peramalan meningkatkan *robustness* dengan mengurangi risiko *overfitting* pada data dan memperbaiki generalisasi terhadap data baru, serta fleksibilitas yang memungkinkan penyesuaian dengan berbagai jenis data dan domain. Meski demikian, tingkat kompleksitas model hibrida menuntut

adanya sumber daya komputasi yang lebih besar serta menyebabkan hasil peramalan menjadi lebih sulit untuk diinterpretasikan. Dalam memilih model peramalan hibrida yang tepat, dibutuhkan adanya pemahaman mendalam tentang karakteristik data serta membutuhkan teknik kalibrasi yang akurat untuk menjaga konsistensi hasil peramalan [11]. Meskipun demikian, model hibrida masih menjadi pilihan utama dalam menghasilkan prediksi yang lebih konsisten dan akurat di berbagai sektor.

Implementasi peramalan memainkan peran penting di berbagai sektor industri yang dapat memberikan wawasan berbasis data yang dapat mendukung pengambilan keputusan strategis. Namun, ada sejumlah tantangan yang harus dihadapi untuk mencapai hasil peramalan yang optimal. Data adalah elemen inti dari setiap model peramalan, di mana ketersediaan data yang memadai, berkualitas, dan representatif sangat penting untuk menghasilkan prediksi yang andal. Tantangan yang sering dihadapi dalam proses peramalan adalah keberadaan data yang tidak lengkap atau hilang. Kondisi seperti ini disebabkan karena adanya kendala teknis pada saat proses pengumpulan data maupun adanya kebijakan privasi yang membatasi akses terhadap informasi tertentu. Teknik komputasi yang kompleks diperlukan untuk memproses data yang hilang sehingga meningkatkan potensi ketidakpastian dalam hasil peramalan. Adanya perbedaan karakteristik dan kompleksitas data yang berasal dari berbagai sumber dengan variasi format serta skala yang tidak seragam menyebabkan timbulnya tantangan tersendiri dalam proses integrasi dan normalisasi data [12]. Akurasi peramalan merupakan salah satu aspek yang paling kritis dalam implementasi model peramalan. Akurasi ini sangat bergantung pada kualitas data, pendekatan dan kemampuan model peramalan dalam menangkap pola data yang kompleks. Data yang digunakan sering kali tidak lengkap dan mengandung *noise* atau bias. Hal ini dapat menyebabkan model peramalan memberikan hasil yang tidak optimal. Kualitas data yang buruk dan tidak dapat direpresentasikan dengan baik dapat menjadi penghalang utama dalam penerapan peramalan [13]. Selain itu, tantangan *overfitting* dan *underfitting* juga sering terjadi. *Overfitting* terjadi ketika model peramalan sangat akurat pada saat proses pelatihan model tetapi gagal melakukan generalisasi pada data baru, sedangkan *underfitting* terjadi ketika model peramalan tidak cukup kompleks untuk mengidentifikasi pola dalam data. Menemukan keseimbangan yang tepat dalam pemilihan model dan parameter adalah tantangan yang memerlukan perhatian khusus [14]. Di sisi lain, banyak model peramalan bergantung pada asumsi bahwa pola masa lalu akan terus berlanjut di masa depan, yang mana keadaan tersebut tidak selalu terjadi, terutama dalam lingkungan yang dinamis seperti pasar saham atau industri teknologi. Ketergantungan pada pola historis dapat membatasi akurasi peramalan dalam kondisi yang tidak stabil [8].

Sejalan dengan perkembangan model peramalan, penelitian pada bidang ini telah menunjukkan kemajuan yang signifikan. Beragam penelitian telah dilakukan untuk mengkaji peramalan dari berbagai sudut pandang, namun sebagian besar masih menitikberatkan pada permasalahan tertentu, seperti penerapan model pembelajaran, penilaian kinerja model, atau penggunaan metode peramalan tertentu pada bidang yang spesifik. Penelitian sebelumnya pada umumnya memiliki ruang lingkup yang terbatas dan belum banyak menawarkan kerangka kerja yang menyeluruh untuk mengoptimalkan penerapan peramalan permintaan. Selain itu, minimnya penggunaan analisis bibliometrik untuk memetakan tren penelitian, pola kolaborasi global, serta kesenjangan dalam literatur menyebabkan pemahaman terhadap arah perkembangan bidang ini menjadi kurang luas. Ringkasan penelitian terdahulu yang berkaitan dengan model peramalan ditampilkan pada Tabel 1.

Tabel 1. Penelitian Terdahulu

Penulis	Tujuan Penelitian	Hasil Penelitian
Sina, L.B.; Secco, C.A.; Blazevic, M.; Nazemi, K. [15]	Meninjau model peramalan hibrida yang menggabungkan model tradisional dan <i>neural network</i> pada data <i>time series</i> , dengan fokus pada peningkatan keakuratan prediksi dibandingkan model peramalan tunggal.	Model peramalan hibrida menunjukkan tingkat akurasi yang lebih tinggi jika ditinjau dari indikator RMSE dan MAPE, serta memiliki potensi besar untuk diterapkan dalam sistem analitik visual sebagai penunjang proses pengambilan keputusan. Berbagai kajian lintas bidang, mulai dari ekonomi hingga lingkungan dan kesehatan, secara konsisten mengungkap keunggulan pendekatan ini, sehingga semakin menegaskan relevansinya dalam pengembangan sistem yang berbasis data.

Jaimin Shah; Darsh Vaidya; Manan Shah [16]	Meninjau model peramalan hibrida dalam konteks prediksi pasar saham yang menekankan penggabungan berbagai pendekatan, seperti ARIMA, LSTM, CNN, serta kombinasi model hibrida lain, guna meningkatkan tingkat akurasi dan efisiensi dalam meramalkan pergerakan harga saham.	Model peramalan hibrida menunjukkan akurasi lebih tinggi dalam peramalan harga saham dibandingkan model tunggal, dengan CNN-LSTM menjadi salah satu model paling efektif untuk prediksi tren saham jangka pendek dan jangka panjang. Analisis juga mengungkapkan potensi model ini dalam aplikasi perdagangan dan pengambilan keputusan berbasis data.
Aamer, A.; Eka Yani, L. ; Alan Priyatna, I. [17]	Meninjau aplikasi model peramalan <i>Machine Learning</i> untuk memprediksi permintaan rantai pasokan. Studi ini berfokus pada algoritma yang digunakan, tren terkini, dan kesenjangan dalam penelitian yang ada..	Penelitian ini menunjukkan bahwa <i>Neural Network</i> (27%), ANN (22%), SVR (18%), dan SVM (10%) adalah model peramalan yang paling banyak digunakan dalam peramalan permintaan. Sebagian besar aplikasi ditemukan di sektor industri (65%). Penelitian ini menyoroti potensi besar <i>Machine Learning</i> dalam meningkatkan akurasi peramalan permintaan untuk mendukung efisiensi rantai pasok.
Palomero, L.; García, V.; Sánchez, J.S. [18]	Meninjau model peramalan berbasis <i>fuzzy</i> pada data <i>time series</i> , dengan fokus pada perkembangan dan penerapannya selama periode 2017 – 2021, serta mengevaluasi kontribusi, tren, dan potensi pengaplikasiannya di berbagai bidang.	Hasil analisis bibliometrik menunjukan bahwa model <i>fuzzy</i> unggul dalam menangani ketidakpastian data. Model peramalan hibrida antara model fuzzy dengan pendekatan lain terbukti mampu meningkatkan akurasi prediksi. Selain itu, kajian ini memetakan tren publikasi global terkait model <i>fuzzy</i> , yang dapat dijadikan landasan dalam pengembangan model-model peramalan yang lebih inovatif di masa mendatang.
Jaramillo, M.; Pavón, W.; Jaramillo, L. [19]	Menilai kontribusi serta keterbatasan dari berbagai model peramalan saat ini, termasuk model <i>Deep Learning</i> seperti LSTM. Penilaian dilakukan melalui analisis bibliometrik terhadap penelitian peramalan konsumsi listrik, dengan tujuan mendukung pengembangan sistem energi yang berkelanjutan.	Pemodelan dinamika konsumsi energi memiliki potensi besar untuk model peramalan seperti LSTM dan <i>Deep Learning</i> . Namun, teknik-teknik ini membutuhkan daya komputasi yang besar dan data berkualitas tinggi. Studi ini menyerukan kerja sama untuk memajukan teknik peramalan energi sekaligus menyoroti hambatan penting seperti keterbatasan data dan kompleksitas teknis.
Hong N. Dao; Wang Chuan Yuan; Aoshi Suzuki; Hitomi Sudo; Li Ye; Debopriyo Roy [20]	Melakukan analisis bibliometrik terhadap penerapan AI dalam peramalan pasar saham, dengan fokus pada model <i>Deep Learning</i> yang mencakup model peramalan hibrida maupun model peramalan tunggal. Penelitian ini juga mengevaluasi keunggulan dan kontribusi model-model tersebut dalam meningkatkan akurasi peramalan pasar saham.	Model peramalan berbasis <i>Deep Learning</i> seperti RNN, LSTM, CNN, dan Transformer menunjukkan tingkat akurasi yang lebih tinggi dibandingkan model tradisional dalam memprediksi pasar saham. Penggunaan model hibrida yang menggabungkan data tekstual dan numerik juga terbukti meningkatkan kinerja prediksi. Penelitian ini turut mengidentifikasi arah pengembangan riset di masa mendatang terkait integrasi AI dalam prediksi pasar saham.

Berdasarkan uraian dari latar belakang dan penelitian terdahulu, dapat disimpulkan bahwa analisis bibliometrik masih jarang digunakan untuk mengevaluasi tren penelitian, mengidentifikasi kesenjangan literatur, dan memetakan kolaborasi global dalam pengembangan model peramalan permintaan. Meskipun telah banyak penelitian yang mengkaji terkait dengan implementasi model peramalan termasuk model hibrida, *machine learning* dan *deep learning* namun penerapannya pada berbagai sektor hingga saat ini belum terintegrasi dan terpisah-pisah. Hingga saat ini masih belum ada kerangka kerja komprehensif yang dapat dijadikan pedoman dalam implementasi model peramalan secara sistematis di berbagai sektor. Tantangan dalam implementasi peramalan berupa karakteristik data yang bervariasi serta tingkat kompleksitas model tidak terpetakan sehingga menyulitkan para praktisi dalam mengatasi tantangan tersebut secara efektif. Penelitian ini bertujuan untuk mengidentifikasi dan memetakan tantangan utama dalam implementasi model peramalan serta menawarkan solusi strategis guna meningkatkan efisiensi dan akurasi peramalan. Upaya tersebut diwujudkan melalui penyusunan kerangka kerja komprehensif dalam implementasi peramalan permintaan. Melalui penelitian ini, diharapkan dapat menyediakan pedoman yang bersifat praktis dalam implementasi peramalan permintaan sehingga hasil dari peramalan dapat optimal dan dapat diaplikasikan di berbagai sektor.

II. METODE

Penelitian ini menggunakan pendekatan metode campuran dengan analisis bibliometrik dan analisis konten. Analisis bibliometrik adalah metode kuantitatif yang digunakan untuk meneliti struktur pengetahuan dan perkembangan bidang penelitian berdasarkan analisis publikasi terkait [21]. Analisis bibliometrik digunakan untuk mengidentifikasi tren penelitian, kesenjangan penelitian, dan kolaborasi global dalam pengembangan model peramalan permintaan. Sedangkan analisis konten adalah metode kualitatif yang digunakan untuk melakukan analisis yang bersifat mendalam terhadap isi dari suatu informasi tertulis atau tercetak [22]. Analisis konten digunakan untuk merumuskan kerangka kerja komprehensif guna mengoptimalkan implementasi peramalan permintaan. Tahapan yang akan ditempuh oleh peneliti dalam melakukan analisis bibliometrik dan analisis konten pada penelitian ini dapat diuraikan sebagai berikut:

1. Melakukan pengumpulan data dari basis data scopus dan mendefinisikan istilah pencarian
2. Melakukan proses pembersihan dan harmonisasi data kemudian mengolah data tersebut dengan menggunakan biblioMagika®, biblioMagika@split dan *Open Refine*.
3. Membuat visualisasi data dengan menggunakan bibliomagika®, VOSviewer, *iimaps* dan *Biblioshiny*.
4. Melakukan interpretasi terhadap hasil yang diperoleh dari visualisasi data.
5. Melakukan analisis konten pada dokumen yang memenuhi kriteria penelitian.


Dalam penelitian ini, data diperoleh dari basis data Scopus. Basis data Scopus dipilih karena memiliki cakupan yang luas meliputi publikasi jurnal, konferensi, serta buku dari berbagai disiplin ilmu sehingga salah satu basis data akademik terbesar di dunia. Selain itu, basis data Scopus dikenal memiliki kredibilitas tinggi karena hanya memuat publikasi yang telah melalui proses seleksi ketat, sehingga kualitas dan keandalan data yang digunakan dalam penelitian ini dapat terjamin [23]. Scopus juga dilengkapi dengan berbagai indikator bibliometrik yang komprehensif, seperti jumlah sitasi, indeks h, serta analisis kolaborasi. Indikator ini sangat berguna untuk mendukung pelaksanaan analisis bibliometrik secara mendalam. Selain itu, kompatibilitas Scopus dengan perangkat lunak analitik seperti *VOSviewer* mempermudah proses pengolahan data, sementara fitur pencarian lanjutannya memungkinkan penyaringan publikasi berdasarkan kata kunci, tahun publikasi maupun jenis dokumen. [24]. Dengan keunggulan tersebut menjadikan Scopus sebagai sumber data yang tepat untuk memproyeksikan tren penelitian secara menyeluruh dan dapat dipercaya.

Kombinasi kata kunci yang digunakan adalah: *TITLE ("Demand Forecasting" OR "Demand Prediction") AND TITLE ("Machine Learning" OR "Deep Learning" OR "Traditional forecasting" OR "Traditional Prediction" OR "Hybrid Ensemble" OR "Hybrid forecasting" OR "Hybrid ")* untuk mengidentifikasi semua publikasi target. Peneliti mengumpulkan publikasi dalam rentang waktu dari tahun 2015 hingga 2024. Pencarian ini menghasilkan total 502 dokumen. Data yang diperoleh dari basis data Scopus selanjutnya diunduh dan disimpan ke dalam dataset Scopus (scopus export refine value.csv, scopus.csv). Dataset tersebut kemudian akan melalui tahapan pembersihan data, harmonisasi data, dan pengolahan data lebih lanjut menggunakan Bibliomagika, BiblioMagika@split dan Open Refine [25], [26]. Setelah pembersihan, harmonisasi data dan pengolahan data selesai dilakukan, langkah berikutnya yang adalah melakukan visualisasi data dengan memanfaatkan bibliomagika, VOSviewer, iimaps dan Biblioshiny. Langkah selanjutnya adalah melakukan interpretasi daripada hasil visualisasi untuk memperoleh pemahaman yang lebih mendalam.

Proses analisis konten dilakukan secara sistematis untuk memastikan setiap informasi yang diolah memiliki validitas dan mendukung tercapainya tujuan penelitian. Analisis konten dilakukan secara mendalam terhadap data yang memenuhi kriteria relevansi dan kualitas data untuk mengidentifikasi pola - pola utama, indikator, dan faktor-faktor yang memengaruhi penerapan model peramalan permintaan. Hal ini bertujuan untuk menyusun kerangka kerja komprehensif yang dapat dijadikan pedoman untuk optimalisasi implementasi peramalan permintaan. Data yang

digunakan diseleksi secara cermat dengan memperhatikan kesesuaiannya terhadap konteks penelitian, sehingga menghasilkan dasar yang kuat dalam pengembangan kerangka kerja yang komprehensif, akurat dan aplikatif.

Kriteria data yang digunakan dalam penelitian ini mencakup dokumen dengan status akses terbuka (*Open Access*) yang memungkinkan akses tanpa batasan dan fleksibel. Jenis dokumen yang dipilih terbatas pada artikel penelitian, untuk memastikan fokus pada karya ilmiah berbasis penelitian. Selanjutnya, hanya dokumen yang ditulis dalam bahasa Inggris yang disertakan dalam analisis untuk memfasilitasi generalisasi dan komunikasi lintas negara. Sumber dokumen dibatasi pada jurnal, yang diakui memiliki kredibilitas dan kualitas yang lebih tinggi dibandingkan sumber lain. Hanya dokumen yang telah mencapai tahap publikasi akhir yang disertakan, untuk memastikan bahwa data yang digunakan sepenuhnya matang dan telah melalui proses penyuntingan dan peninjauan sejawat. Selain itu, penelitian ini mengintegrasikan data dari berbagai bidang dan domain untuk mendukung analisis lintas domain, memungkinkan identifikasi pola dan wawasan yang relevan di berbagai sektor. Dengan cakupan multidisiplin ini, penelitian ini memberikan dasar yang kuat untuk mengoptimalkan implementasi peramalan permintaan di berbagai konteks industri dan akademis. Data yang memenuhi kriteria data dalam penelitian ini berjumlah 144 dokumen.



Gambar 1. Proses Filterisasi dan *Screening* Data

III. HASIL DAN PEMBAHASAN

Untuk mendapatkan gambaran umum sekaligus wawasan yang lebih mendalam mengenai penelitian dibidang peramalan permintaan, sejumlah statistik umum dari data yang memenuhi kriteria pencarian akan dievaluasi dan dikaji dan dianalisis berdasarkan beberapa aspek berikut:

1. Profil dokumen, termasuk metrik sitasi dan bidang penelitian,
2. Produktivitas penelitian dari waktu ke waktu, untuk mengidentifikasi tren perkembangan penelitian,
3. Publikasi berdasarkan peneliti untuk mengetahui peneliti paling berkontribusi dan keterkaitan antar peneliti,
4. Publikasi berdasarkan negara untuk mengidentifikasi distribusi global hasil penelitian,
5. Kata Kunci (*keywords*) untuk mengetahui topik penelitian yang sedang berkembang.

A. Profil Dokumen

Tabel 2 menampilkan ringkasan metrik sitasi untuk dokumen yang dikumpulkan hingga 28 Desember 2024. Data metrik sitasi diperoleh dari hasil pemrosesan dokumen menggunakan biblioMagika® dengan mengimpor *file* berformat CSV yang bersumber dari basis data Scopus, yang kemudian disajikan dalam bentuk sitasi mentah.

Tabel 2. Metrik Kutipan

Informasi Utama	Data
Tahun Publikasi	2015 - 2024
Total Publikasi	502
Tahun Sitasi	11
Jumlah Penulis Kontributor	1887
Jumlah Dokumen yang Disitasi	375
Total Sitasi	8.060
Rata-rata Sitasi per Dokumen	16,06
Rata-rata Sitasi per Dokumen yang Disitasi	21,49
Rata-rata Sitasi per Tahun	895,56
Rata-rata Sitasi per Penulis	4,27
Rata-rata Penulis per Dokumen	3,76
Total Sitasi dalam h-Core	6.678
Indeks h	49
Indeks g	75
Indeks m	4,455

Sumber: Diolah menggunakan biblioMagika®

Studi ini mencakup publikasi bertema peramalan permintaan selama periode 10 tahun dari 2015 hingga 2024, dengan total 502 dokumen yang diterbitkan. Dari keseluruhan jumlah dokumen tersebut, 375 dokumen telah menerima sitasi. Total sitasi yang tercatat mencapai 8.060, dengan rata-rata 16,06 sitasi per dokumen dan 21,49 sitasi untuk setiap dokumen yang disitasi. Jumlah rata-rata sitasi yang tercatat per tahun adalah sebanyak 895,56, yang mencerminkan tingkat dampak tahunan yang relative stabil. Penelitian dalam bidang peramalan melibatkan sebanyak 1.887 penulis berkontribusi, dengan rata-rata 4,27 sitasi per penulis serta 3,76 penulis pada setiap dokumen. Selain itu, sitasi yang terkonsentrasi dalam h-core mencapai angka 6.678 yang mendukung nilai h-indeks sebesar 49. Angka ini menunjukan bahwa terdapat 49 dokumen yang masing-masing setidaknya memperoleh 49 sitasi. Indeks g tercatat sebesar 75, yang menunjukkan pengaruh kolektif dari dokumen-dokumen yang banyak dikutip, sementara nilai indeks m sebesar 4,455 mencerminkan tingkat pertumbuhan dampak yang tinggi di bidang penelitian ini. Secara keseluruhan, temuan ini mencerminkan tingkat produktivitas yang tinggi dan partisipasi kolaboratif yang luas antar peneliti serta dampak ilmiah yang kuat pada bidang yang diteliti.

Tabel 3. Bidang Penelitian

Bidang Penelitian	Total Publikasi	Presentase
Teknik	273	54,38%
Ilmu Komputer	266	52,99%
Matematika	126	25,10%
Energi	103	20,52%
Ilmu Lingkungan	72	14,34%
Ilmu Keputusan	63	12,55%
Ilmu Sosial	60	11,95%
Bisnis, Manajemen dan Akuntansi	53	10,56%
Fisika dan Astronomi	44	8,76%
Ilmu Material	29	5,78%

Sumber: Diolah menggunakan biblioMagika®

Selanjutnya, publikasi dalam penelitian ini dikategorikan berdasarkan bidang penelitian sebagaimana disajikan pada tabel 3. Bidang Teknik (54,38%) dan Ilmu Komputer (52,99%) mendominasi jumlah publikasi dalam penelitian dibidang peramalan permintaan. Diikuti oleh bidang Matematika (25,10%), Energi (20,52%), dan Ilmu Lingkungan (14,34%). Bidang lainnya, seperti Ilmu Keputusan (12,55%), Ilmu Sosial (11,95%) dan Bisnis, Manajemen dan Akuntansi (10,56%) juga memberikan kontribusi yang signifikan. Temuan ini mengindikasikan bahwa fokus utama publikasi berada pada bidang teknik dan sains terapan, sementara bidang lain berperan sebagai pendukung dengan proporsi publikasi yang lebih rendah.

B. Tren Publikasi

Hasil dari penelitian ini memperlihatkan adanya tren peningkatan yang signifikan dalam jumlah publikasi dari tahun ke tahun, sebagaimana disajikan pada tabel 4. Pada tahun 2015 dan 2016 jumlah publikasi masih relatif kecil dengan masing-masing hanya 8 dokumen atau sekitar 1,59% dari total keseluruhan publikasi. Jumlah publikasi meningkat pada tahun 2017 menjadi 20 dokumen (3,98%). Tren pertumbuhan dalam publikasi terus berlanjut dan mencapai titik puncak pada tahun 2024 dengan 114 dokumen yang setara dengan 22,71% dari total publikasi. Selama periode 2015-2014, sebanyak 1.887 penulis berkontribusi pada publikasi di bidang peramalan permintaan. Seiring dengan meningkatnya jumlah publikasi, kontribusi penulis juga ikut mengalami kenaikan. Tercata sebanyak 431 penulis terlibat dalam penelitian pada tahun 2024 yang merupakan jumlah tertinggi dibandingkan tahun-tahun sebelumnya. Secara keseluruhan, peningkatan ini mencerminkan adanya pertumbuhan penelitian yang pesat dengan kontribusi terbesar terjadi dalam beberapa tahun terakhir. Hal ini mendandakan adanya fokus yang semakin besar terhadap topik yang dikaji sepanjang periode analisis.


Table 4. Publikasi berdasarkan Tahun

Tahun	TP	%	Cumm. TP	Cumm. %	NCA	NCP	TC	C/P	C/CP
2015	8	1,59%	8	1,59%	27	6	332	41,50	55,33
2016	8	1,59%	16	3,19%	29	8	153	19,13	19,13
2017	20	3,98%	36	7,17%	64	17	546	27,30	32,12
2018	18	3,59%	54	10,76%	66	17	965	53,61	56,76
2019	35	6,97%	89	17,73%	134	32	1252	35,77	39,13
2020	45	8,96%	134	26,69%	178	43	1586	35,24	36,88
2021	63	12,55%	197	39,24%	240	60	1395	22,14	23,25
2022	92	18,33%	289	57,57%	344	84	1165	12,66	13,87
2023	99	19,72%	388	77,29%	374	65	499	5,04	7,68
2024	114	22,71%	502	100,00%	431	43	167	1,46	3,88
Total Keseluruhan	502	100,00%	-	-	1887	375	8060	16,06	21,49

Catatan: TP=Total jumlah publikasi; NCA=Jumlah penulis yang berkontribusi; NCP=Jumlah publikasi yang disitasi; TC=Total Sitasi; C/P=rata-rata sitasi per publikasi; C/CP=rata-rata sitasi per publikasi yang disitasi.

Sumber: Diolah menggunakan biblioMagika®


Gambar 2 memperlihatkan grafik distribusi jumlah dokumen yang dipublikasikan serta jumlah sitasi per tahun selama rentang waktu tahun 2015-2024. Grafik ini menunjukkan tren pertumbuhan yang kuat pada jumlah publikasi, dengan pertumbuhan yang relatif stabil hingga mencapai puncak sebanyak 114 publikasi pada tahun 2024. Sebaliknya, jumlah sitasi tahunan menunjukkan tren yang berbeda. Jumlah sitasi tertinggi terjadi pada tahun 2020 dengan jumlah total 1.586 sitasi, meskipun pada tahun 2020 jumlah publikasi lebih rendah dibandingkan tahun-tahun setelahnya. Grafik tersebut juga menunjukkan bahwa dokumen yang dipublikasikan membutuhkan waktu untuk mendapatkan pengakuan dan memberikan dampak pada penelitian lain, sebagaimana tercermin dalam jumlah sitasi.



Gambar 2. Total Publikasi dan Kutipan Berdasarkan Tahun
Sumber: Diolah menggunakan biblioMagika®

C. Publikasi berdasarkan Peneliti

Penelitian ini menganalisis lebih lanjut terkait dengan kolaborasi antar penulis dengan melakukan *co-authorship analysis* menggunakan aplikasi VOSviewer. Analisis ini difokuskan kepada penulis yang memiliki pengaruh dan memiliki lebih dari 4 sitasi yang mana perhitungannya dilakukan dengan metode *fractional counting*. Elemen - elemen seperti warna, ukuran lingkaran, ukuran teks, dan ketebalan garis penghubung digunakan untuk menunjukkan kekuatan hubungan antarpemulis. Penulis yang terhubung, ditandai dengan warna yang sama, biasanya berada dalam satu kelompok. Sebagai contoh yang ditunjukkan pada gambar 4, Ravinesh C. Deo (warna merah) merupakan salah satu penulis sentral dan menunjukkan hubungan erat dengan beberapa penulis seperti S. Ali Pourmousavi dan Sujan Ghimire. Kelompok dengan warna merah terlihat menonjol karena kontribusinya yang besar dalam jaringan kolaborasi. Gambar 4 juga menunjukkan bahwa Jan F. Adamowski (warna ungu) memiliki hubungan langsung dengan Mukesh K. Tiwari dan penulis lain, tetapi tampak sebagai kelompok yang lebih kecil.



Gambar 3. Peta visualisasi jaringan *co-authorship* berdasarkan penulis yang memiliki minimal empat sitasi (dengan metode *fractional counting*).

Sumber: Diolah menggunakan VOSviewer

D. Publikasi berdasarkan Negara


Tabel 5. 10 Negara Teratas yang Berkontribusi pada Publikasi

Negara	TP	NCA	NCP	TC	C/P	C/CP	<i>h</i>	<i>g</i>	<i>m</i>
China	141	206	101	2957	20,97	29,28	26	54	2,364
India	72	112	46	929	12,90	20,20	15	30	1,364
Amerika Serikat	29	47	23	653	22,52	28,39	13	25	1,625
Turki	22	30	14	309	14,05	22,07	9	17	1,000
Iran	20	25	17	363	18,15	21,35	10	19	1,250
Korea Selatan	20	32	18	367	18,35	20,39	9	19	0,900
Spanyol	19	23	16	360	18,95	22,50	8	18	0,727
Britania Raya	19	27	14	433	22,79	30,93	10	19	1,111
Kanada	17	22	17	508	29,88	29,88	12	17	1,091
Australia	16	19	14	703	43,94	50,21	9	16	1,125

Catatan: TP=Total jumlah publikasi; NCA=Jumlah penulis yang berkontribusi; NCP=Jumlah publikasi yang disitasi; TC=Total Sitasi; C/P=rata-rata sitasi per publikasi; C/CP=rata-rata sitasi per publikasi yang disitasi; *h*=indeks *h*; *g*=indeks *g*.

Sumber: Diolah menggunakan biblioMagika®

Tabel 5 menampilkan sepuluh negara teratas yang berkontribusi pada publikasi terkait peramalan permintaan. China menjadi negara peringkat pertama didunia dengan jumlah publikasi terbanyak, yaitu 141 publikasi, dan total 2.957 sitasi. Data ini menunjukkan bahwa China memiliki pengaruh signifikan terhadap publikasi yang berkaitan dengan peramalan permintaan. India dengan total publikasi sejumlah 72 dan Amerika Serikat dengan total publikasi sejumlah 29 menempati posisi kedua dan ketiga. Australia merupakan negara yang memiliki dampak terbesar berdasarkan rata-rata sitasi per publikasi, dengan nilai 43,94, meskipun hanya memiliki 16 publikasi terkait dengan peramalan permintaan. Temuan ini mengindikasikan bahwa negara maju telah memiliki peranan penting dalam penelitian dibidang peramalan permintaan dibandingkan dengan negara berkembang.




Gambar 4. Peta visualisasi jaringan *co-authorship* berdasarkan negara yang memiliki minimal sepuluh publikasi (dengan metode *fractional counting*).

Sumber: Diolah menggunakan VOSviewer

Gambar 4 menampilkan visualisasi dari hasil analisis *co-authorship* untuk memetakan kolaborasi antar negara menggunakan aplikasi VOSviewer. Analisis ini difokuskan pada negara-negara dengan minimal sepuluh publikasi sebanyak 10 atau lebih dengan perhitungan dilakukan menggunakan metode *fractional counting*. Lingkaran terbesar dimiliki oleh China yang mencerminkan jumlah kontribusi dan pengaruh yang besar dalam penelitian dibidang peramalan permintaan. Negara lain seperti India dan Amerika Serikat memiliki peran besar yang terlihat dari posisi mereka yang

strategis dengan banyak koneksi ke negara lain. Di kawasan Asia Tenggara, negara seperti Indonesia, Malaysia, dan Thailand membentuk jaringan yang lebih kecil yang mana hal tersebut menunjukkan kolaborasi regional yang signifikan, terutama dengan negara-negara Asia Lainnya. Temuan ini menggambarkan pola kolaborasi global yang didominasi oleh negara-negara maju, dengan peran pendukung dari negara berkembang. Gambar 5 menyajikan sebaran publikasi di bidang penelitian peramalan permintaan diseluruh dunia yang terindeks oleh basis data Scopus yang memberikan gambaran distribusi geografis secara global.




Gambar 5. Sebaran Publikasi Penelitian Peramalan Permintaan Seluruh Dunia Terindeks Scopus.

Sumber: Diolah menggunakan *iipmaps.com*

E. Analisis Kata Kunci


Dalam penelitian ini, kata kunci yang digunakan oleh penulis juga dipetakan menggunakan aplikasi VOSviewer sebagaimana divisualisasikan pada gambar 6. Visualisasi ini menggunakan warna, ukuran lingkaran, ukuran font, dan ketebalan garis penghubung untuk menggambarkan hubungan dan kekuatan keterkaitan antar kata kunci yang digunakan oleh penulis. Hasil analisis kata kunci yang digunakan penulis menunjukkan adanya empat kluster dalam penelitian yang berkaitan dengan peramalan permintaan. Kluster pertama berwarna merah, kluster kedua berwarna hijau, kluster ketiga berwarna biru, dan kluster keempat berwarna kuning.



Gambar 6. Peta Visualisasi Jaringan Kata Kunci Penulis

Sumber: Diolah menggunakan VOSviewer


Kata kunci Machine Learning dan Deep Learning yang termasuk dalam klaster pertama berwarna merah yang terlihat menjadi poros utama dalam penelitian ini, ditandai dengan lingkaran besar serta banyaknya koneksi ke kata kunci lainnya. Pada klaster kedua yang berwarna hijau terdapat kata kunci seperti Demand Forecasting dan Long-Short Term Memory (LSTM) menunjukkan koneksi yang kuat, dan menandakan bahwa kata kunci ini sering digunakan dalam penelitian peramalan permintaan. Klaster ketiga dengan warna biru kecil mencakup kata kunci seperti Artificial Intelligence. Secara keseluruhan, visualisasi ini menunjukkan bahwa penelitian ini fokus pada integrasi model machine learning dan deep learning untuk meningkatkan akurasi prediksi di berbagai domain, dengan hubungan yang kuat antar subtopik yang mengindikasikan tren kolaborasi dan integrasi dalam penelitian.



Gambar 7. Kata Kunci Terpopuler
Sumber: Diolah menggunakan biblioMagika®

Gambar 7 menyajikan kata kunci penulis yang paling sering digunakan pada penelitian yang terkait dengan peramalan permintaan. *Machine Learning* menjadi kata kunci yang paling dominan dengan kemunculan tertinggi yakni sebanyak 168 kali, diikuti oleh *Deep Learning* dan *Demand Forecasting*, masing-masing sebanyak 128 kali. Kata kunci lain seperti *Long-Short Term Memory (LSTM)*, *Artificial Neural Network* dan *Support Vector Machine* menunjukkan adanya fokus penelitian pada pengintegrasian *Machine Learning* dan *Deep Learning* untuk kebutuhan peningkatan akurasi peramalan dalam penerapannya diberbagai domain.

Pada penelitian ini, disajikan peta tematik pada gambar 8. Peta tematik alat visualisasi untuk menganalisis tema penelitian berdasarkan dua parameter utama yaitu tingkat pengembangan (*density*) dan relevansi (*centrality*). Tujuannya adalah untuk mengidentifikasi tema yang sudah mapan, tema yang sedang berkembang, serta tema yang mulai menurun atau kurang relevan. Peta ini dibagi menjadi empat kuadran yaitu *Motor Themes* (tema inti yang relevan dan berkembang), *Basic Themes* (tema dasar yang penting tetapi kurang berkembang), *Niche Themes* (tema spesifik dengan pengembangan tinggi tetapi kurang relevan), dan *Emerging or Declining Themes* (tema yang kurang berkembang atau mulai ditinggalkan) [27]. Tema *forecasting*, *demand forecasting*, dan *machine learning* yang berada di tengah peta menjadi tema sentral yang memiliki peran sebagai penghubung antara tema spesifik dan tema dasar pada penelitian di bidang peramalan permintaan. *Basic Themes*, seperti *electric power utilization*, *neural networks*, dan *mean square error* yang berada di kuadran kanan bawah merupakan tema fundamental dengan relevansi tinggi tetapi tingkat perkembangannya masih relatif rendah. Sementara itu, tema seperti *forecasting method*, *water demand*, dan *prediction* berada pada *Niche Themes* di kuadran kiri atas yang menunjukkan tema spesifik dengan pengembangan tinggi tetapi memiliki relevansi yang terbatas. Kuadran kiri bawah, *Emerging or Declining Themes*, tidak menampilkan tema yang signifikan, menunjukkan bahwa tidak ada tema yang jelas-jelas sedang berkembang atau menurun. Secara keseluruhan, peta ini memberikan gambaran struktur konseptual dan fokus penelitian yang saat ini sedang berkembang dalam domain studi tersebut.



Gambar 8. Peta Tematik Kata Kunci
Sumber: Diolah menggunakan *Biblioshiny*

F. Perkembangan Peramalan Permintaan

Dalam satu dekade terakhir, model peramalan permintaan telah mengalami perkembangan yang signifikan. Kebutuhan akan akurasi dan efisiensi model peramalan yang lebih tinggi, mendorong adanya perubahan dari model peramalan tradisional menuju model peramalan hibrida. Model peramalan tradisional memiliki peran penting dalam perkembangan ini karena digunakan sebagai dasar untuk memprediksi permintaan di masa depan melalui analisis data historis dan faktor-faktor yang relevan [28]. Namun model peramalan tradisional terlalu bergantung pada kualitas data historis yang seringkali tidak memadai atau tidak lengkap terutama pada produk baru dengan riwayat penjualan yang terbatas [29]. Selain itu, model peramalan tradisional memiliki keterbatasan dalam menangkap pola data yang kompleks dan nonlinier, sehingga dapat menurunkan akurasi prediksi pada lingkungan yang dinamis [30]. Seiring dengan perkembangan teknologi, *machine learning* menawarkan kemampuan yang lebih baik dalam memproses data berskala besar dan pola yang kompleks dibandingkan model peramalan tradisional, serta memberikan kemampuan peramalan yang lebih adaptif dan kuat [31]. Selanjutnya, kemunculan *deep learning* semakin meningkatkan kinerja model peramalan dengan kemampuannya dalam menangkap hubungan nonlinier dan rumit yang ada dalam data [32]. Pengujian model peramalan pada data empiris menunjukkan bahwa model hibrida mampu memberikan hasil yang lebih akurat dibandingkan model peramalan tradisional maupun *machine learning* atau *deep learning* tunggal [33].

Model hibrida merupakan model peramalan yang pada umumnya mengintegrasikan model tradisional dengan *machine learning* dan atau *deep learning*, sehingga memungkinkan untuk mengidentifikasi fluktuasi tren permintaan jangka pendek dan jangka panjang secara bersamaan. Di sektor energi, model hibrida LSTM-CNN terbukti meningkatkan akurasi hasil peramalan kebutuhan energi listrik dengan menggabungkan informasi kontekstual seperti suhu dan kelembaban [34]. Model hibrida lain seperti CNN-GRU yang digunakan untuk memprediksi permintaan air di perkotaan memiliki akurasi peramalan yang tinggi dengan MAPE mencapai 1,65% dalam jangka waktu 24 jam [35]. Di sektor pariwisata, model hibrida CNN-LSTM berhasil memprediksi permintaan pariwisata pasca-COVID-19 di Vietnam. CNN berperan dalam mengidentifikasi pola spasial pada data pariwisata, sementara LSTM digunakan untuk menganalisis pola perubahan permintaan dari waktu ke waktu, sehingga model ini relevan untuk mendukung pengambilan keputusan pada kondisi permintaan yang dinamis [36]. Model hibrida *Autodencoder-Stacked* juga terbukti meningkatkan akurasi peramalan permintaan pariwisata dengan memanfaatkan data minat dan perilaku konsumen secara real-time [37]. Model hibrida tidak hanya meningkatkan akurasi peramalan, tetapi juga mampu mengakomodasi berbagai sumber data, sehingga memperkuat kemampuan adaptasinya terhadap perkembangan tren pariwisata serta mendukung pengambilan keputusan strategis.

Peramalan permintaan di sektor ritel telah mengalami kemajuan yang signifikan dengan adanya model peramalan hibrida. Model hibrida LSTM-Random Forest terbukti meningkatkan akurasi peramalan permintaan pada ritel multichannel. Model ini memungkinkan perusahaan memahami pola permintaan dan hubungan data yang kompleks dan nonlinier secara lebih baik untuk mendukung perencanaan dan pengambilan keputusan operasional yang lebih efektif [38]. Model hibrida SVM-LSTM menegaskan fleksibilitas pendekatan hibrida dalam sektor ritel makanan,

dengan menunjukkan akurasi peramalan yang lebih tinggi dibandingkan model peramalan tradisional ARIMA [39]. Temuan ini menunjukkan bahwa model hibrida memberikan pendekatan yang lebih komprehensif dalam memahami perilaku konsumen, mengoptimalkan pengelolaan persediaan, serta mendukung pengambilan keputusan manajerial dalam peramalan permintaan ritel.

Industri manufaktur semakin banyak mengadopsi model peramalan hibrida untuk meningkatkan akurasi prediksi dan efisiensi operasional. Model hibrida GA–LSTM terbukti meningkatkan akurasi peramalan pada produksi blok beton dengan mencapai nilai MAPE sebesar 2,8%, yang secara signifikan lebih baik dibandingkan model tradisional yang memiliki nilai MAPE antara 4% hingga 6% [40]. Model hibrida LSTM–*Random Forest* yang digunakan untuk peramalan permintaan rantai pasok menunjukkan kinerja yang lebih unggul dengan nilai Mean Squared Error (MSE) sebesar 0,25, dibandingkan dengan nilai 0,45 pada model peramalan tunggal [41]. Peramalan permintaan di sektor keuangan, ekonomi, dan perawatan kesehatan juga memperoleh manfaat dari model hibrida. Model hibrida LSTM–ARIMA terbukti efektif dalam memprediksi permintaan ekonomi pada periode pra-pandemi dan selama pandemi, serta menunjukkan akurasi dan ketahanan yang lebih tinggi dibandingkan model peramalan tradisional [42]. Model hibrida AR–HOW yang mengintegrasikan ARIMA dan *Holt–Winters* untuk peramalan permintaan farmasi terbukti secara signifikan mengurangi kesalahan peramalan dan mengungguli model peramalan tradisional seperti *Exponential Smoothing State Space* [43].

Sektor pertanian juga mengalami peningkatan yang signifikan dalam peramalan permintaan melalui penerapan model hibrida. Model hibrida *Holt–Winters*–SVM yang terbukti mampu menurunkan nilai *Mean Absolute Percentage Error* (MAPE) menjadi 6,2% dalam peramalan permintaan benih bawang merah, dibandingkan dengan 9,5% pada model *Holt–Winters* tunggal [44]. Model hibrida IWRAM yang digunakan untuk peramalan kebutuhan air irigasi mencapai nilai *Mean Absolute Percentage Error* (MAPE) sebesar 5,1%, lebih rendah dibandingkan model tradisional dengan MAPE sebesar 7,3% [45]. Temuan ini menegaskan efektivitas model hibrida dalam mengoptimalkan alokasi sumber daya serta meningkatkan kualitas pengambilan keputusan bagi para pemangku kepentingan di sektor pertanian.

G. Kategori Peramalan Permintaan

Peramalan permintaan mempunyai peran penting dalam perencanaan strategis maupun operasional di berbagai sektor industri. Peramalan permintaan memungkinkan organisasi untuk memperkirakan tingkat permintaan terhadap produk dan layanan jasa di masa mendatang. Berdasarkan jangka waktunya, peramalan permintaan dapat dibedakan menjadi peramalan jangka pendek, jangka menengah, dan jangka panjang, sebagaimana tercantum pada Tabel 6. Setiap kategori peramalan tersebut memiliki tujuan serta pendekatan metodologis yang spesifik, yang disesuaikan dengan kebutuhan pengambilan keputusan bisnis maupun penyusunan kebijakan.

Table 6. Kategori Peramalan Permintaan berdasarkan Jangka Waktu

Kategori Peramalan	Jangka Waktu	Tujuan
Jangka Pendek (<i>Short-Term</i>)	Menit s/d Minggu	1. Perencanaan operasional 2. Alokasi sumber daya
Jangka Menengah (<i>Medium-Term</i>)	Minggu s/d Bulan	1. Manajemen persediaan 2. Perencanaan produksi
Jangka Panjang (<i>Long-Term</i>)	Bulan s/d Tahun	1. Perencanaan strategis 2. Pengembangan infrastruktur 3. Pengambilan keputusan investasi

Peramalan permintaan jangka pendek mencakup rentang waktu dari beberapa menit hingga beberapa minggu dan berperan penting dalam pengambilan keputusan operasional secara langsung. Jenis peramalan ini berfokus pada data berfrekuensi tinggi dan fluktuasi jangka pendek untuk mengoptimalkan manajemen persediaan, penjadwalan produksi, serta alokasi sumber daya. Berbagai metode, seperti analisis deret waktu, model *machine learning*, dan pendekatan hibrida, digunakan untuk meningkatkan akurasi peramalan. Sejumlah studi menunjukkan bahwa model hibrida yang menggabungkan teknik *machine learning*, seperti *Long Short-Term Memory* (LSTM), dengan metode statistik tradisional efektif dalam memprediksi permintaan pada sektor yang bersifat volatil, seperti listrik dan air [46], [47]. Selain itu, penerapan model lanjutan yang mengintegrasikan teknik koreksi kesalahan terbukti mampu meningkatkan ketepatan prediksi dalam sistem pengambilan keputusan *real-time* [48], [49].

Peramalan permintaan jangka menengah mencakup periode beberapa minggu hingga beberapa bulan dan berperan penting dalam perencanaan taktis. Jenis peramalan ini umumnya mengintegrasikan pola musiman dan tren siklis, sehingga sangat relevan bagi industri yang permintaannya dipengaruhi oleh faktor cuaca, kondisi ekonomi, dan perilaku konsumen. Penerapan kombinasi teknik *seasonal decomposition* dengan algoritma *machine learning* telah terbukti meningkatkan tingkat akurasi peramalan jangka menengah, khususnya pada sektor-sektor seperti ritel dan

transportasi [50], [51]. Selain itu, model hibrida yang mengintegrasikan analisis *time series* dengan teknik *deep learning* menunjukkan performa prediktif yang lebih tinggi, ehingga mendukung organisasi dalam menyelaraskan jadwal produksi, mengelola rantai pasok, serta mengoptimalkan tingkat persediaan secara lebih efektif [17], [52].

Peramalan permintaan jangka panjang mencakup periode beberapa bulan hingga beberapa tahun dan berperan penting dalam pengambilan keputusan strategis serta alokasi sumber daya. Berbeda dengan peramalan jangka pendek dan menengah, peramalan jangka panjang sangat bergantung pada indikator makroekonomi, tren demografis, dan data historis untuk memproyeksikan kecenderungan permintaan di masa depan. Berbagai metode, seperti analisis regresi, model ekonometrika, dan teknik peramalan berbasis *deep learning*, telah banyak digunakan untuk meningkatkan akurasi prediksi jangka panjang [53]. Studi terbaru menunjukkan bahwa model *deep learning* berbasis *Long Short-Term Memory* (LSTM) mampu menangkap ketergantungan jangka panjang dalam data, sehingga efektif diterapkan pada sektor pariwisata, transportasi, serta perencanaan infrastruktur energi. Pendekatan ini mendukung organisasi dalam pengambilan keputusan investasi, perencanaan ekspansi kapasitas, dan mitigasi risiko akibat fluktuasi permintaan jangka panjang [54].


H. Faktor yang Mempengaruhi Peramalan Permintaan

Faktor eksternal secara signifikan memengaruhi pengumpulan data dan pemilihan model dalam peramalan permintaan, sehingga berdampak langsung pada akurasi dan reliabilitas hasil prediksi. Kondisi ekonomi, seperti inflasi, tingkat pengangguran, dan pertumbuhan ekonomi, membentuk perilaku konsumsi, di mana perlambatan ekonomi menurunkan permintaan barang non-esensial, sementara ekspansi ekonomi meningkatkannya [54], [55]. Integrasi indikator ekonomi ke dalam model peramalan dapat meningkatkan akurasi dengan menangkap perubahan perilaku konsumen [49]. Selain itu, faktor musiman dan temporal, termasuk musim, hari libur, dan kondisi cuaca, menyebabkan fluktuasi permintaan pada sektor seperti ritel dan energi, sehingga model yang mempertimbangkan faktor-faktor tersebut mampu memprediksi pola permintaan siklis secara lebih akurat [56]. Kemajuan teknologi, khususnya dalam *big data* dan *machine learning*, telah merevolusi peramalan permintaan dengan meningkatkan akurasi melalui kecerdasan buatan yang mampu mengidentifikasi pola historis yang kompleks, serta didukung oleh pengumpulan data *real time* berbasis IoT yang meningkatkan granularitas dan responsivitas model [51], [57], [58]. Selain itu, faktor sosial dan perilaku, seperti perubahan preferensi konsumen, demografi, gaya hidup, serta pertumbuhan *e-commerce*, telah mengubah pola pembelian tradisional sehingga menuntut penyesuaian model peramalan, termasuk melalui analisis sentimen media sosial untuk menangkap tren konsumen yang dinamis [59], [60], [61]. Faktor lingkungan, seperti perubahan iklim dan cuaca ekstrem, turut memengaruhi permintaan pada sektor pertanian, energi, dan sumber daya air, sehingga integrasi data lingkungan menjadi penting untuk meningkatkan kesiapan dan akurasi prediksi. Selain itu, pola permintaan dibentuk oleh kebijakan dan regulasi pemerintah serta dinamika persaingan, termasuk strategi harga, pemasaran, dan inovasi produk. Kondisi ini mendorong organisasi untuk menyesuaikan model peramalan agar lebih mampu menghadapi perubahan pasar. [62], [63].

Proses pengumpulan data dan pemilihan model peramalan dipengaruhi secara signifikan oleh faktor internal, sehingga perannya sangat penting dalam peramalan permintaan. Kualitas dan ketersediaan data, pendekatan metodologis, kompetensi internal, serta proses operasional menjadi faktor-faktor yang langsung menentukan akurasi dan efektivitas model peramalan. Kualitas data yang rendah, tidak lengkap, atau memiliki tingkat granularitas yang rendah dapat menghasilkan prediksi yang keliru, sementara data berkualitas tinggi dengan volume dan granularitas yang memadai terbukti meningkatkan kinerja model peramalan [64], [65]. Pemilihan model yang tepat juga krusial karena setiap metode memiliki keunggulan dan keterbatasan yang bergantung pada konteks penerapannya, di mana model hibrida dan pendekatan *ensemble* berbasis *machine learning* terbukti mampu meningkatkan akurasi prediksi [66], [67]. Selain itu, keahlian sumber daya manusia dan ketersediaan infrastruktur teknologi yang memadai mendukung pemilihan, implementasi, dan interpretasi model secara optimal, termasuk penerapan teknik *deep learning* [53], [68]. Proses operasional internal, seperti manajemen data yang efektif dan penerapan mekanisme umpan balik melalui kompensasi kesalahan, juga berkontribusi terhadap peningkatan ketepatan peramalan secara berkelanjutan [69], [70].

I. Alur Kerja Peramalan Permintaan

Implementasi peramalan permintaan merupakan proses yang bersifat multidimensi dan terdiri atas beberapa tahapan berurutan untuk memastikan akurasi dan reliabilitas pada berbagai sektor industri, seperti manufaktur, ritel, pertanian, keuangan, dan kesehatan. Proses ini dapat diklasifikasikan ke dalam pendekatan model tunggal dan strategi model hibrida, yang masing-masing memiliki metodologi berbeda dalam pengelolaan data, pemilihan model, pelatihan, dan evaluasi. Gambar 9 menggambarkan alur kerja dalam implementasi peramalan permintaan.



Gambar 9. Alur Kerja Peramalan Permintaan

Gambar 9 menunjukkan alur kerja yang diusulkan untuk optimalisasi implementasi peramalan permintaan. Alur kerja tersebut menerjemahkan konsep peramalan menjadi proses terstruktur yang terdiri dari enam tahap, yaitu pengumpulan data, prapemrosesan data, pemilihan model, pelatihan dan validasi model, evaluasi kinerja, serta interpretasi hasil. Tahapan tersebut bertujuan untuk meningkatkan akurasi peramalan, menjaga konsistensi metodologis, serta memperkuat kemampuan organisasi dalam menghadapi ketidakpastian. Tahap pertama dalam melakukan peramalan permintaan adalah pengumpulan data yang relevan yang akan dijadikan sebagai dasar utama pengembangan model peramalan. Pada sektor manufaktur data seperti data penjualan historis, jadwal produksi, dan tingkat persediaan merupakan komponen penting dalam peramalan permintan [71]. Pada kektor ritel, data penjualan, perilaku konsumen, dan variasi musiman untuk meningkatkan akurasi peramalan [68]. Sektor pertanian umumnya mengandalkan data kondisi iklim dan data dari hasil panen [44], sementara sektor keuangan memanfaatkan indikator makroekonomi dan pola permintaan historis, serta sektor kesehatan bergantung pada volume pasien dan pola penyakit musiman [16], [72].

Tahap kedua adalah prapemrosesan data. Proses ini digunakan menangani data hilang, melakukan normalisasi data, dan memilih fitur yang relevan. Data yang hilang dapat menimbulkan bias dalam peramalan, sehingga organisasi menerapkan teknik imputasi, seperti penggunaan nilai rata-rata, median, atau metode yang lebih kompleks [44]. Proses normalisasi data dilakukan untuk memastikan bahwa setiap variabel memiliki berkontribusi secara seimbang dalam analisis sekaligus meminimalkan adanya bias selama pemodelan berlangsung [47]. Sementara itu, proses seleksi fitur dilakukan untuk membantu mengurangi redundansi serta meningkatkan efisiensi model, dengan penerapan metode seperti *Recursive Feature Elimination* dan *LASSO* untuk memastikan bahwa hanya variabel yang paling signifikan yang dapat memengaruhi hasil peramalan [73]. Pemilihan model peramalan bergantung pada karakteristik data dan

kebutuhan spesifik masing-masing industri. Model tunggal, seperti ARIMA, secara tradisional digunakan pada kondisi permintaan yang relatif stabil dan dapat diprediksi, misalnya pada sektor manufaktur [74]. Sementara itu, *Long Short-Term Memory* (LSTM) sebagai teknik *deep learning* unggul dalam menangkap ketergantungan jangka panjang pada data deret waktu, sehingga sesuai untuk lingkungan yang dinamis seperti ritel dan energi [54], [73]. Model *Random Forest* efektif diterapkan pada sektor dengan hubungan nonlinier yang kompleks serta memiliki ketahanan terhadap pencilan [75]. Sebaliknya, model hibrida yang memadukan keunggulan dari berbagai model untuk meningkatkan akurasi prediksi. Misalnya, model hibrida LSTM-ARIMA yang menggabungkan kelebihan dari model LSTM dalam memodelkan dinamika temporal dengan kekuatan analisis statistik dari ARIMA [74]. Model CNN-LSTM telah terbukti sangat efektif dalam menangani kasus seperti peramalan energi yang melibatkan data dengan fitur multidimensi [76]. Kombinasi model peramalan lain, seperti *Random Forest* yang dipadukan dengan XGBoost, memberikan pendekatan *ensemble* yang efektif untuk meningkatkan varians sekaligus mengurangi bias sehingga hasil peramalan menjadi lebih akurat [77].

Tahap pelatihan dan validasi model dilakukan dengan memasukkan data pelatihan ke dalam model peramalan yang telah dipilih. Proses ini menyesuaikan parameter untuk memperoleh kinerja yang optimal. Selain itu, proses ini membagi data menjadi set pelatihan, validasi, dan pengujian untuk memastikan kemampuan generalisasi model. Teknik *k-fold cross-validation* sering digunakan untuk mengevaluasi ketahanan model secara menyeluruh, dan telah terbukti menghasilkan evaluasi yang andal pada berbagai arsitektur jaringan saraf dalam studi peramalan permintaan listrik [78]. Setelah proses pelatihan selesai dilakukan, kinerja model peramalan akan dievaluasi menggunakan metrik seperti *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Error* (MAE) untuk menilai akurasi hasil peramalan secara menyeluruh [71]. Sebagai contoh, model LSTM menunjukkan tingkat akurasi yang lebih tinggi dibandingkan dengan model tradisional berdasarkan nilai RMSE dan MAPE khususnya dalam menangkap pola nonlinier yang terdapat pada data [79]. Model hibrida juga mampu meningkatkan kinerja secara signifikan dibandingkan pendekatan tunggal yang ditunjukkan oleh nilai MAPE yang lebih rendah melalui penerapan teknik ensemble atau hibrida [51]. Tahap akhir adalah interpretasi hasil, yang tidak hanya berfokus pada metrik akurasi, tetapi juga pada pemahaman pengaruh berbagai fitur terhadap pola permintaan, termasuk keterkaitan faktor eksternal seperti indikator ekonomi dalam peramalan permintaan pada sektor keuangan [80].

IV. SIMPULAN

Penelitian ini menyajikan tinjauan yang menyeluruh terkait dengan perkembangan penelitian pada peramalan permintaan, terutama dalam konteks meningkatnya volatilitas pasar dan kemajuan teknologi. Transformasi teoritis dan metodologis yang signifikan dalam praktik peramalan diidentifikasi melalui analisis bibliometrik terhadap 502 publikasi yang terindeks di Scopus selama periode 2015–2024, serta analisis konten terhadap 144 studi terpilih. Hasil analisis bibliometrik menunjukkan adanya pertumbuhan publikasi yang substansial dan berkelanjutan, terutama setelah tahun 2020, hal ini mencerminkan adanya peningkatan perhatian global terhadap peramalan berbasis data di tengah ketidakpastian ekonomi dan gangguan rantai pasok. Disiplin teknik dan ilmu komputer menjadi sumber utama penelitian ini, dengan China, India, dan Amerika Serikat sebagai kontributor utama, didukung oleh jaringan kolaborasi internasional yang semakin erat. Hasil pemetaan kata kunci mengungkap bahwa *machine learning*, *deep learning*, dan model hibrida menjadi tema penelitian yang paling dominan selama periode penelitian yang menandakan adanya pergeseran paradigma dari pendekatan model tradisional ke model yang adaptif berbasis kecerdasan buatan. Analisis konten lebih lanjut memberikan wawasan mendalam mengenai implementasi peramalan permintaan di berbagai sektor industri. Temuan penelitian menunjukkan bahwa kinerja peramalan dipengaruhi secara bersamaan oleh faktor eksternal, seperti fluktuasi makroekonomi, perubahan lingkungan, dan dinamika sosial, serta faktor internal organisasi, yang mencakup kualitas data, infrastruktur teknologi, dan kompetensi analitis. Dalam konteks tersebut, model hibrida secara konsisten menampilkan kinerja yang lebih unggul dibandingkan model tradisional maupun model kecerdasan buatan tunggal, melalui integrasi penalaran statistik dan kecerdasan komputasional.

Berdasarkan temuan tersebut, penelitian ini mengusulkan suatu kerangka kerja implementasi peramalan permintaan yang mencakup tahapan pengumpulan data, prapemrosesan, pemilihan model, pelatihan dan validasi, evaluasi kinerja, serta interpretasi hasil. Kerangka kerja yang diusulkan dapat difungsikan sebagai pedoman baik secara konseptual maupun praktis bagi organisasi dalam upaya meningkatkan akurasi hasil peramalan permintaan, menguatkan pengambilan keputusan serta meningkatkan resistensi organisasi dalam menghadapi keadaan yang tidak pasti. Selain itu, kerangka kerja ini juga dapat dijadikan penghubung antara penelitian teoretis dengan aplikasi manajerial melalui struktur yang replikatif dan dapat disesuaikan dengan berbagai macam konteks industri. Penelitian ini memiliki keterbatasan berupa ketergantungan pada basis data Scopus dan publikasi dalam Bahasa Inggris yang dapat berpotensi untuk membatasi representativitas global. Belum adanya validasi empiris berbasis data industri juga menjadikan penelitian ini memiliki banyak celah untuk dikembangkan. Penerapan model model hibrida membutuhkan adanya sumber daya komputasi yang besar dan keahlian teknis yang tidak selalu tersedia secara merata, terutama bagi organisasi yang memiliki skala kecil dan menengah. Oleh karena itu, penelitian selanjutnya disarankan untuk

mengembangkan studi kasus lintas sector dalam menerapkan model peramalan probabilistik, yang mengintegrasikan pendekatan *explainable artificial intelligence* (XAI) untuk meningkatkan transparansi dan inklusivitas. Perluasan cakupan bibliometrik ke basis data non-Inggris, serta studi longitudinal yang menggabungkan evolusi riset dengan validasi industri, juga dianggap penting untuk memperkuat pemahaman mengenai dampak nyata dari inovasi metodologis dalam praktik peramalan permintaan.

REFERENSI

- [1] T. Zhang, Z. Zhang, and G. Xue, "Mitigating the disturbances of events on tourism demand forecasting," *Ann. Oper. Res.*, vol. 342, no. 1, pp. 1019–1040, Nov. 2024, doi: 10.1007/s10479-023-05626-6.
- [2] J. V. Filho, A. Scortegagna, A. P. D. S. D. Vieira, and P. A. Jaskowiak, "Machine learning for water demand forecasting: Case study in a Brazilian coastal city," *Water Pract. Technol.*, vol. 19, no. 5, pp. 1586–1602, May 2024, doi: 10.2166/wpt.2024.096.
- [3] J. S. Armstrong, Ed., *Principles of Forecasting: A Handbook for Researchers and Practitioners*, vol. 30. in International Series in Operations Research & Management Science, vol. 30. Boston, MA: Springer US, 2001. doi: 10.1007/978-0-306-47630-3.
- [4] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice, 2nd edition*. Australia, 2018. [Online]. Available: OTexts.com/fpp2
- [5] G. E. P. Box, G. M. Jenkins, and G. C. Reinsel, *Time Series Analysis*, 1st ed. in Wiley Series in Probability and Statistics. Wiley, 2008. doi: 10.1002/9781118619193.
- [6] G. Shmueli and K. C. Lichtendahl, *Practical time series forecasting with R: a hands-on guide*, Second edition. Erscheinungsort nicht ermittelbar: Axelrod Schnall Publishers, 2018.
- [7] N. U. Moroff, E. Kurt, and J. Kamphues, "Machine Learning and Statistics: A Study for assessing innovative Demand Forecasting Models," *Procedia Comput. Sci.*, vol. 180, pp. 40–49, 2021, doi: 10.1016/j.procs.2021.01.127.
- [8] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, "Statistical and Machine Learning forecasting methods: Concerns and ways forward," *PLOS ONE*, vol. 13, no. 3, p. e0194889, Mar. 2018, doi: 10.1371/journal.pone.0194889.
- [9] F. Ullah, X. Zhang, M. Khan, M. Abid, and A. Mohamed, "A Novel Hybrid Ensemble Learning Approach for Enhancing Accuracy and Sustainability in Wind Power Forecasting," *Comput. Mater. Contin.*, vol. 79, no. 2, pp. 3373–3395, 2024, doi: 10.32604/cmc.2024.048656.
- [10] Z. Cao, C. Wan, Z. Zhang, F. Li, and Y. Song, "Hybrid Ensemble Deep Learning for Deterministic and Probabilistic Low-Voltage Load Forecasting," *IEEE Trans. Power Syst.*, vol. 35, no. 3, pp. 1881–1897, May 2020, doi: 10.1109/TPWRS.2019.2946701.
- [11] A. A. Mamun, Md. Sohel, N. Mohammad, Md. S. Haque Sunny, D. R. Dipta, and E. Hossain, "A Comprehensive Review of the Load Forecasting Techniques Using Single and Hybrid Predictive Models," *IEEE Access*, vol. 8, pp. 134911–134939, 2020, doi: 10.1109/ACCESS.2020.3010702.
- [12] A. Badshah, A. Daud, R. Alharbey, A. Banjar, A. Bukhari, and B. Alshemaimri, "Big data applications: overview, challenges and future," *Artif. Intell. Rev.*, vol. 57, no. 11, p. 290, Sep. 2024, doi: 10.1007/s10462-024-10938-5.
- [13] A. Siddiqi *et al.*, "A survey of big data management: Taxonomy and state-of-the-art," *J. Netw. Comput. Appl.*, vol. 71, pp. 151–166, Aug. 2016, doi: 10.1016/j.jnca.2016.04.008.
- [14] V. Cerqueira, L. Torgo, F. Pinto, and C. Soares, "Arbitrage of forecasting experts," *Mach. Learn.*, vol. 108, no. 6, pp. 913–944, Jun. 2019, doi: 10.1007/s10994-018-05774-y.
- [15] L. B. Sina, C. A. Secco, M. Blazevic, and K. Nazemi, "Hybrid Forecasting Methods—A Systematic Review," *Electronics*, vol. 12, no. 9, p. 2019, Apr. 2023, doi: 10.3390/electronics12092019.
- [16] J. Shah, D. Vaidya, and M. Shah, "A comprehensive review on multiple hybrid deep learning approaches for stock prediction," *Intell. Syst. Appl.*, vol. 16, p. 200111, Nov. 2022, doi: 10.1016/j.iswa.2022.200111.
- [17] A. Aamer, L. P. Eka Yani, and I. M. Alan Priyatna, "Data Analytics in the Supply Chain Management: Review of Machine Learning Applications in Demand Forecasting," *Oper. Supply Chain Manag. Int. J.*, pp. 1–13, Dec. 2020, doi: 10.31387/oscm0440281.
- [18] L. Palomero, V. García, and J. S. Sánchez, "Fuzzy-Based Time Series Forecasting and Modelling: A Bibliometric Analysis," *Appl. Sci.*, vol. 12, no. 14, p. 6894, Jul. 2022, doi: 10.3390/app12146894.
- [19] M. Jaramillo, W. Pavón, and L. Jaramillo, "Adaptive Forecasting in Energy Consumption: A Bibliometric Analysis and Review," *Data*, vol. 9, no. 1, p. 13, Jan. 2024, doi: 10.3390/data9010013.
- [20] H. N.Dao, W. ChuanYuan, A. Suzuki, H. Sudo, L. Ye, and D. Roy, "AI in Stock Market Forecasting: A Bibliometric Analysis," *SHS Web Conf.*, vol. 194, p. 01003, 2024, doi: 10.1051/shsconf/202419401003.

- [21] A. Ahmi, H. Elbardan, and R. H. Raja Mohd Ali, "Bibliometric Analysis of Published Literature on Industry 4.0," in *2019 International Conference on Electronics, Information, and Communication (ICEIC)*, Auckland, New Zealand: IEEE, Jan. 2019, pp. 1–6. doi: 10.23919/ELINFOCOM.2019.8706445.
- [22] H. Heriyanto, "Thematic Analysis sebagai Metode Menganalisa Data untuk Penelitian Kualitatif," *Anuva*, vol. 2, no. 3, p. 317, Nov. 2018, doi: 10.14710/anuva.2.3.317-324.
- [23] J. Baas, M. Schotten, A. Plume, G. Côté, and R. Karimi, "Scopus as a curated, high-quality bibliometric data source for academic research in quantitative science studies," *Quant. Sci. Stud.*, vol. 1, no. 1, pp. 377–386, Feb. 2020, doi: 10.1162/qss_a_00019.
- [24] A. Caputo and M. Kargina, "A user-friendly method to merge Scopus and Web of Science data during bibliometric analysis," *J. Mark. Anal.*, vol. 10, no. 1, pp. 82–88, Mar. 2022, doi: 10.1057/s41270-021-00142-7.
- [25] A. Ahmi, "OpenRefine: An approachable tool for cleaning and harmonizing bibliographical data," presented at the 27TH International Meeting Of Thermophysics 2022, Dalešice, Czech Republic, 2023, p. 030006. doi: 10.1063/5.0164724.
- [26] A. Ahmi, "bibliomagika." 2024. [Online]. Available: <https://bibliomagika.com>
- [27] K. Amin, Z. Ni'mah, and A. Susanto, "Bibliometric Analysis: Development of Scientific Publications on 'Islamic Education' Based on Titles in the Scopus Database 1980-2023," *Maharot J. Islam. Educ.*, vol. 7, no. 1, p. 15, Jun. 2023, doi: 10.28944/maharot.v7i1.1078.
- [28] J. Silva, A. Senior Naveda, J. García Guliany, W. Niebles Núñez, and H. Hernández Palma, "Forecasting Electric Load Demand through Advanced Statistical Techniques," *J. Phys. Conf. Ser.*, vol. 1432, no. 1, p. 012031, Jan. 2020, doi: 10.1088/1742-6596/1432/1/012031.
- [29] R. Kalla, S. Murikinjeri, and R. Abbaiah, "An Improved Demand Forecasting with Limited Historical Sales Data," in *2020 International Conference on Computer Communication and Informatics (ICCCI)*, Coimbatore, India: IEEE, Jan. 2020, pp. 1–5. doi: 10.1109/ICCCI48352.2020.9104090.
- [30] M. Zohdi, M. Rafiee, V. Kayvanfar, and A. Salamiraad, "Demand forecasting based machine learning algorithms on customer information: an applied approach," *Int. J. Inf. Technol.*, vol. 14, no. 4, pp. 1937–1947, Jun. 2022, doi: 10.1007/s41870-022-00875-3.
- [31] V. Sharma, Ü. Cali, B. Sardana, M. Kuzlu, D. Banga, and M. Pipattanasomporn, "Data-driven short-term natural gas demand forecasting with machine learning techniques," *J. Pet. Sci. Eng.*, vol. 206, p. 108979, Nov. 2021, doi: 10.1016/j.petrol.2021.108979.
- [32] E. Aldahmani, A. Alzubi, and K. Iyiola, "Demand Forecasting in Supply Chain Using Uni-Regression Deep Approximate Forecasting Model," *Appl. Sci.*, vol. 14, no. 18, p. 8110, Sep. 2024, doi: 10.3390/app14188110.
- [33] F. Nussipova, S. Rysbekov, Z. Abdiakhmetova, and A. Kartbayev, "Optimizing loss functions for improved energy demand prediction in smart power grids," *Int. J. Electr. Comput. Eng. IJECE*, vol. 14, no. 3, p. 3415, Jun. 2024, doi: 10.11591/ijece.v14i3.pp3415-3426.
- [34] M. Kim, W. Choi, Y. Jeon, and L. Liu, "A Hybrid Neural Network Model for Power Demand Forecasting," *Energies*, vol. 12, no. 5, p. 931, Mar. 2019, doi: 10.3390/en12050931.
- [35] H. Namdari, S. M. Ashrafi, and A. Haghighi, "Deep learning-based short-term water demand forecasting in urban areas: A hybrid multichannel model," *AQUA — Water Infrastruct. Ecosyst. Soc.*, vol. 73, no. 3, pp. 380–395, Mar. 2024, doi: 10.2166/aqua.2024.200.
- [36] T. Nguyen-Da, Y.-M. Li, C.-L. Peng, M.-Y. Cho, and P. Nguyen-Thanh, "Tourism Demand Prediction after COVID-19 with Deep Learning Hybrid CNN–LSTM—Case Study of Vietnam and Provinces," *Sustainability*, vol. 15, no. 9, p. 7179, Apr. 2023, doi: 10.3390/su15097179.
- [37] H. Laaroussi, F. Guerouate, and M. Sbihi, "A novel hybrid deep learning approach for tourism demand forecasting," *Int. J. Electr. Comput. Eng. IJECE*, vol. 13, no. 2, p. 1989, Apr. 2023, doi: 10.11591/ijece.v13i2.pp1989-1996.
- [38] S. Punia, K. Nikolopoulos, S. P. Singh, J. K. Madaan, and K. Litsiou, "Deep learning with long short-term memory networks and random forests for demand forecasting in multi-channel retail," *Int. J. Prod. Res.*, vol. 58, no. 16, pp. 4964–4979, Aug. 2020, doi: 10.1080/00207543.2020.1735666.
- [39] N. Nassibi, H. Fasihuddin, and L. Hsairi, "Demand Forecasting Models for Food Industry by Utilizing Machine Learning Approaches," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 3, 2023, doi: 10.14569/IJACSA.2023.01403101.
- [40] H. AL-Khazraji, A. Nasser, and S. Khlil, "An intelligent demand forecasting model using a hybrid of metaheuristic optimization and deep learning algorithm for predicting concrete block production," *IAES Int. J. Artif. Intell. IJ-AI*, vol. 11, no. 2, p. 649, Jun. 2022, doi: 10.11591/ijai.v11i2.pp649-657.
- [41] A. E. Filali, E. H. B. Lahmer, S. E. Filali, and A. Jadli, "Application of Deep Learning in the Supply Chain Management: A comparison of forecasting demand for electrical products using different ANN methods," in *2022 International Conference on Electrical, Computer and Energy Technologies (ICECET)*, Prague, Czech Republic: IEEE, Jul. 2022, pp. 1–7. doi: 10.1109/ICECET55527.2022.9872903.

- [42] A. Kolková and A. Ključnikov, "Demand forecasting: AI-based, statistical and hybrid models vs practice-based models - the case of SMEs and large enterprises," *Econ. Sociol.*, vol. 15, no. 4, pp. 39–62, Dec. 2022, doi: 10.14254/2071-789X.2022/15-4/2.
- [43] R. Siddiqui, M. Azmat, S. Ahmed, and S. Kummer, "A hybrid demand forecasting model for greater forecasting accuracy: the case of the pharmaceutical industry," *Supply Chain Forum Int. J.*, vol. 23, no. 2, pp. 124–134, Apr. 2022, doi: 10.1080/16258312.2021.1967081.
- [44] Y. Zhu, Y. Zhao, J. Zhang, N. Geng, and D. Huang, "Spring onion seed demand forecasting using a hybrid Holt-Winters and support vector machine model," *PLOS ONE*, vol. 14, no. 7, p. e0219889, Jul. 2019, doi: 10.1371/journal.pone.0219889.
- [45] C. Dang *et al.*, "IWRAM: A hybrid model for irrigation water demand forecasting to quantify the impacts of climate change," *Agric. Water Manag.*, vol. 291, p. 108643, Feb. 2024, doi: 10.1016/j.agwat.2023.108643.
- [46] R. Porteiro, L. Hernández-Callejo, and S. Nesmachnow, "Electricity demand forecasting in industrial and residential facilities using ensemble machine learning," *Rev. Fac. Ing. Univ. Antioquia*, Jun. 2020, doi: 10.17533/udea.redin.20200584.
- [47] S. Wu, H. Han, B. Hou, and K. Diao, "Hybrid Model for Short-Term Water Demand Forecasting Based on Error Correction Using Chaotic Time Series," *Water*, vol. 12, no. 6, p. 1683, Jun. 2020, doi: 10.3390/w12061683.
- [48] H. Namdari, S. M. Ashrafi, and A. Haghighi, "Deep learning-based short-term water demand forecasting in urban areas: A hybrid multichannel model," *AQUA — Water Infrastruct. Ecosyst. Soc.*, vol. 73, no. 3, pp. 380–395, Mar. 2024, doi: 10.2166/aqua.2024.200.
- [49] S. Shan, H. Ni, G. Chen, X. Lin, and J. Li, "A Machine Learning Framework for Enhancing Short-Term Water Demand Forecasting Using Attention-BiLSTM Networks Integrated with XGBoost Residual Correction," *Water*, vol. 15, no. 20, p. 3605, Oct. 2023, doi: 10.3390/w15203605.
- [50] T. Aichner and V. Santa, "Demand Forecasting Methods and the Potential of Machine Learning in the FMCG Retail Industry," in *Serving the Customer*, T. Aichner, Ed., Wiesbaden: Springer Fachmedien Wiesbaden, 2023, pp. 215–252. doi: 10.1007/978-3-658-39072-3_8.
- [51] S. Zhao and X. Mi, "A Novel Hybrid Model for Short-Term High-Speed Railway Passenger Demand Forecasting," *IEEE Access*, vol. 7, pp. 175681–175692, 2019, doi: 10.1109/ACCESS.2019.2957612.
- [52] Z. H. Kilimci *et al.*, "An Improved Demand Forecasting Model Using Deep Learning Approach and Proposed Decision Integration Strategy for Supply Chain," *Complexity*, vol. 2019, no. 1, p. 9067367, Jan. 2019, doi: 10.1155/2019/9067367.
- [53] A. Salamanis, G. Xanthopoulou, D. Kehagias, and D. Tzovaras, "LSTM-Based Deep Learning Models for Long-Term Tourism Demand Forecasting," *Electronics*, vol. 11, no. 22, p. 3681, Nov. 2022, doi: 10.3390/electronics11223681.
- [54] E. Choi, S. Cho, and D. K. Kim, "Power Demand Forecasting using Long Short-Term Memory (LSTM) Deep-Learning Model for Monitoring Energy Sustainability," *Sustainability*, vol. 12, no. 3, p. 1109, Feb. 2020, doi: 10.3390/su12031109.
- [55] A. Kolková and A. Ključnikov, "Demand forecasting: AI-based, statistical and hybrid models vs practice-based models - the case of SMEs and large enterprises," *Econ. Sociol.*, vol. 15, no. 4, pp. 39–62, Dec. 2022, doi: 10.14254/2071-789X.2022/15-4/2.
- [56] S. N. V. B. Rao *et al.*, "Day-Ahead Load Demand Forecasting in Urban Community Cluster Microgrids Using Machine Learning Methods," *Energies*, vol. 15, no. 17, p. 6124, Aug. 2022, doi: 10.3390/en15176124.
- [57] M. Aci and D. Yergök, "Demand Forecasting for Food Production Using Machine Learning Algorithms: A Case Study of University Refectory," *Teh. Vjesn. - Tech. Gaz.*, vol. 30, no. 6, Dec. 2023, doi: 10.17559/TV-20230117000232.
- [58] L. Viverit, C. Y. Heo, L. N. Pereira, and G. Tiana, "Application of machine learning to cluster hotel booking curves for hotel demand forecasting," *Int. J. Hosp. Manag.*, vol. 111, p. 103455, May 2023, doi: 10.1016/j.ijhm.2023.103455.
- [59] A. J. Del Real, F. Dorado, and J. Durán, "Energy Demand Forecasting Using Deep Learning: Applications for the French Grid," *Energies*, vol. 13, no. 9, p. 2242, May 2020, doi: 10.3390/en13092242.
- [60] S. Sikhwal and S. Sen, "Comparative Analysis of Machine Learning Models for Money Demand Forecasting in the Indian Economy," *High. Sch. Econ. Econ. J.*, vol. 28, no. 1, pp. 133–158, 2024, doi: 10.17323/1813-8691-2024-28-1-133-158.
- [61] R. K. Shiwakoti, C. Charoenlarnopparut, and K. Chapagain, "A Deep Learning Approach for Short-Term Electricity Demand Forecasting: Analysis of Thailand Data," *Appl. Sci.*, vol. 14, no. 10, p. 3971, May 2024, doi: 10.3390/app14103971.
- [62] N. E. Alamdari, M. F. Anjos, and G. Savard, "Application of machine learning techniques in railway demand forecasting," *Int. J. Revenue Manag.*, vol. 12, no. 1/2, p. 132, 2021, doi: 10.1504/IJRM.2021.114970.

- [63] L. Kannari, J. Kiljander, K. Piira, J. Piippo, and P. Koponen, "Building Heat Demand Forecasting by Training a Common Machine Learning Model with Physics-Based Simulator," *Forecasting*, vol. 3, no. 2, pp. 290–302, Apr. 2021, doi: 10.3390/forecast3020019.
- [64] M. S. AL-Musaylh, R. C. Deo, Y. Li, and J. F. Adamowski, "Two-phase particle swarm optimized-support vector regression hybrid model integrated with improved empirical mode decomposition with adaptive noise for multiple-horizon electricity demand forecasting," *Appl. Energy*, vol. 217, pp. 422–439, May 2018, doi: 10.1016/j.apenergy.2018.02.140.
- [65] K. D. Chaudhuri and B. Alkan, "A hybrid extreme learning machine model with harris hawks optimisation algorithm: an optimised model for product demand forecasting applications," *Appl. Intell.*, vol. 52, no. 10, pp. 11489–11505, Aug. 2022, doi: 10.1007/s10489-022-03251-7.
- [66] J. C. Preciado, Á. E. Prieto, R. Benitez, R. Rodríguez-Echeverría, and J. M. Conejero, "A High-Frequency Data-Driven Machine Learning Approach for Demand Forecasting in Smart Cities," *Sci. Program.*, vol. 2019, pp. 1–16, Jun. 2019, doi: 10.1155/2019/8319549.
- [67] Y. Yang, L. Han, Y. Wang, and J. Wang, "China's Energy Demand Forecasting Based on the Hybrid PSO-LSSVR Model," *Wirel. Commun. Mob. Comput.*, vol. 2022, pp. 1–12, Jan. 2022, doi: 10.1155/2022/7584646.
- [68] M. A. Khan *et al.*, "Effective Demand Forecasting Model Using Business Intelligence Empowered With Machine Learning," *IEEE Access*, vol. 8, pp. 116013–116023, 2020, doi: 10.1109/ACCESS.2020.3003790.
- [69] G. Liu, D. Savic, and G. Fu, "Short-term water demand forecasting using data-centric machine learning approaches," *J. Hydroinformatics*, vol. 25, no. 3, pp. 895–911, May 2023, doi: 10.2166/hydro.2023.163.
- [70] Z. Wang, Z. Chen, Y. Yang, C. Liu, X. Li, and J. Wu, "A hybrid Autoformer framework for electricity demand forecasting," *Energy Rep.*, vol. 9, pp. 3800–3812, Dec. 2023, doi: 10.1016/j.egyr.2023.02.083.
- [71] I.-F. Chen and C.-J. Lu, "Demand Forecasting for Multichannel Fashion Retailers by Integrating Clustering and Machine Learning Algorithms," *Processes*, vol. 9, no. 9, p. 1578, Sep. 2021, doi: 10.3390/pr9091578.
- [72] Y. Huang *et al.*, "Demand prediction of medical services in home and community-based services for older adults in China using machine learning," *Front. Public Health*, vol. 11, p. 1142794, Mar. 2023, doi: 10.3389/fpubh.2023.1142794.
- [73] M. Nasser, T. Falatouri, P. Brandtner, and F. Darbanian, "Applying Machine Learning in Retail Demand Prediction—A Comparison of Tree-Based Ensembles and Long Short-Term Memory-Based Deep Learning," *Appl. Sci.*, vol. 13, no. 19, p. 11112, Oct. 2023, doi: 10.3390/app131911112.
- [74] C.-C. Wang, H.-T. Chang, and C.-H. Chien, "Hybrid LSTM-ARMA Demand-Forecasting Model Based on Error Compensation for Integrated Circuit Tray Manufacturing," *Mathematics*, vol. 10, no. 13, p. 2158, Jun. 2022, doi: 10.3390/math10132158.
- [75] S. Punia, K. Nikolopoulos, S. P. Singh, J. K. Madaan, and K. Litsiou, "Deep learning with long short-term memory networks and random forests for demand forecasting in multi-channel retail," *Int. J. Prod. Res.*, vol. 58, no. 16, pp. 4964–4979, Aug. 2020, doi: 10.1080/00207543.2020.1735666.
- [76] S. S. and S. S. J. S.D., "Improving Energy Demand Prediction in IoT Based Smart Grids through Hybrid CNN-LSTM Modelling With Modified Sea Lion Algorithm," *Int. J. Electr. Electron. Eng.*, vol. 10, no. 9, pp. 221–231, Sep. 2023, doi: 10.14445/23488379/IJEEE-V10I9P121.
- [77] A. Mitra, A. Jain, A. Kishore, and P. Kumar, "A Comparative Study of Demand Forecasting Models for a Multi-Channel Retail Company: A Novel Hybrid Machine Learning Approach," *Oper. Res. Forum*, vol. 3, no. 4, p. 58, Sep. 2022, doi: 10.1007/s43069-022-00166-4.
- [78] A. Jain and S. C. Gupta, "Evaluation of electrical load demand forecasting using various machine learning algorithms," *Front. Energy Res.*, vol. 12, p. 1408119, Jun. 2024, doi: 10.3389/fenrg.2024.1408119.
- [79] L. Munkhdalai, K. H. Park, E. Batbaatar, N. Theera-Umpon, and K. H. Ryu, "Deep Learning-Based Demand Forecasting for Korean Postal Delivery Service," *IEEE Access*, vol. 8, pp. 188135–188145, 2020, doi: 10.1109/ACCESS.2020.3030938.
- [80] A. Sanford, "Information content of option prices: Comparing analyst forecasts to option-based forecasts," *North Am. J. Econ. Finance*, vol. 73, pp. 102197–102197, 2024, doi: 10.1016/j.najef.2024.102197.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.