

From Predictive to Prescriptive Maintenance in Power Generation: An Integrated Five-Layer Framework Validated through Systematic Comparative Analysis
[Dari Pemeliharaan Prediktif ke Prescriptive di Pembangkit Listrik: Five-Layer Framework Terintegrasi Dengan Validasi Menggunakan Systematic Comparative Analysis]

Ahmad Fauzan¹⁾, Rita Ambarwati Sukmono^{*2)}

¹⁾Program Studi Magister Manajemen, Universitas Muhammadiyah Sidoarjo

²⁾Program Studi Magister Manajemen, Universitas Muhammadiyah Sidoarjo

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

Abstract. *Prescriptive maintenance (RxM) has emerged as a strategic evolution in power generation, advancing beyond reactive and predictive approaches by leveraging technologies associated with Industry 4.0. The potential of RxM lies in its ability to support proactive and data driven decision processes. However, existing frameworks remain fragmented and lacking the modularity in complex and variable power plant environments. This study conducts a systematic literature review guided by five research questions to explore the conceptual foundations of RxM, the enabling technologies that support its application including the Internet of Things, machine learning, digital twins, and deep reinforcement learning, the structural components that define its architecture, the primary challenges to its implementation, and the strategies used for validation. Based on these findings, a modular and adaptive RxM framework is developed and conceptually validated using a systematic comparative analysis against seven benchmark studies. The proposed framework integrates cloud-edge computing infrastructures, advanced analytical layers, multi criteria evaluation mechanisms, and iterative feedback processes. The comparative results emphasize the framework's ability to support integrated and responsive maintenance strategies while remaining compatible with industrial platforms. Its design supports both new and existing operational environments, allowing gradual integration without requiring complete system replacement. This study offers a generalizable reference model that can guide organizations seeking to transition from predictive to prescriptive maintenance in power generation. Future research should prioritize field implementation, real time validation, and alignment with broader industry goals including environmental sustainability, transparent artificial intelligence, and improved protection of digital infrastructure..*

Keywords: - Prescriptive maintenance, Systematic literature review, Systematic Comparative Analysis, Prescriptive Maintenance Framework

Abstrak. *Prescriptive maintenance (RxM) telah muncul sebagai evolusi strategis dalam sektor pembangkitan listrik, melampaui pendekatan reaktif dan prediktif dengan memanfaatkan teknologi yang terkait dengan Industry 4.0. Potensi dari RxM terletak pada kemampuannya untuk mendukung proses pengambilan keputusan yang proaktif dan berbasis data. Namun, kerangka kerja yang ada saat ini masih terfragmentasi dan belum memiliki modularitas yang memadai dalam lingkungan pembangkit listrik yang kompleks dan bervariasi. Studi ini melakukan systematic literature review yang dipandu oleh lima pertanyaan penelitian untuk mengeksplorasi landasan konseptual dari RxM, teknologi pendukung yang memungkinkan penerapannya termasuk Internet of Things, machine learning, digital twins, dan deep reinforcement learning, komponen struktural yang membentuk arsitekturnya, tantangan utama dalam implementasinya, serta strategi yang digunakan untuk proses validasi. Berdasarkan temuan-temuan tersebut, dikembangkan sebuah kerangka RxM yang modular dan adaptif, dan divalidasi secara konseptual menggunakan systematic comparative analysis terhadap tujuh studi acuan. Kerangka yang diusulkan ini mengintegrasikan infrastruktur cloud-edge computing, analytical layers tingkat lanjut, mekanisme evaluasi multikriteria, serta proses feedback yang bersifat iteratif. Hasil perbandingan menekankan kemampuan kerangka ini dalam mendukung strategi pemeliharaan yang terintegrasi dan responsif, sekaligus tetap kompatibel dengan platform industri. Desainnya mendukung baik lingkungan operasional baru maupun yang sudah ada, memungkinkan integrasi secara bertahap tanpa memerlukan penggantian sistem secara menyeluruh. Studi ini menawarkan model referensi yang dapat digeneralisasi untuk membimbing organisasi yang ingin bertransisi dari predictive ke prescriptive maintenance dalam pembangkitan listrik. Penelitian selanjutnya sebaiknya memprioritaskan implementasi lapangan, validasi secara waktu nyata, serta penyelarasan dengan tujuan industri yang lebih luas, termasuk keberlanjutan lingkungan, kecerdasan buatan yang transparan, dan perlindungan infrastruktur digital yang lebih baik.*

Kata Kunci: - Pemeliharaan Prescriptive, Kajian Literatur Tersistematis, Comparative Analysis Tersistematis, Kerangka Kerja Pemeliharaan Prescriptive

I. PENDAHULUAN

Selama beberapa dekade terakhir, praktik pemeliharaan industri telah mengalami pergeseran paradigma, bertransisi dari pendekatan reaktif dan berbasis waktu menuju strategi yang semakin cerdas dan berbasis data, yang berpuncak pada adopsi prescriptive maintenance sebagai solusi visioner dalam manajemen aset. Prescriptive maintenance (RxM) merepresentasikan pendekatan yang proaktif dan berbasis data yang tidak hanya memprediksi potensi kegagalan, tetapi juga merekomendasikan tindakan optimal berdasarkan data operasional real-time, system constraints, dan kondisi yang terus berkembang. Dalam industri-industri dengan risiko tinggi seperti pembangkitan listrik, di mana reliability, efficiency, dan asset longevity sangat krusial, RxM memiliki potensi untuk secara signifikan mentransformasi perencanaan dan pelaksanaan pemeliharaan. Percepatan Industry 4.0 semakin meningkatkan kelayakan RxM dengan memungkinkan integrasi teknologi-teknologi canggih termasuk Internet of Things (IoT), digital twins, machine learning, dan infrastruktur cloud-edge hybrid ke dalam sistem manajemen aset. Teknologi-teknologi ini memungkinkan akuisisi data secara mulus, complex analytics, dan autonomous decision support, sehingga memfasilitasi strategi pemeliharaan yang dinamis dan kontekstual. Meskipun proliferasi teknologi-teknologi tersebut terus meningkat, kerangka RxM yang ada sering kali masih terfragmentasi dan terbatas pada konteks industri tertentu. Banyak model saat ini hanya menekankan pada komponen-komponen pendukung tertentu, tanpa mencakup arsitektur komprehensif yang mengintegrasikan fungsi-fungsi utama seperti mekanisme eksekusi dan pembelajaran berbasis feedback yang berkelanjutan [1], [2], [3]. Selain itu, integrasi dengan sistem lama seperti SCADA (Supervisory Control and Data Acquisition) dan CMMS (Computerized Maintenance Management Systems) masih belum konsisten, yang semakin mempersulit upaya implementasi di lingkungan nyata [4], [5].

Beberapa studi ilmiah telah berupaya mengembangkan model prescriptive maintenance di berbagai domain industri. Studi-studi seperti yang dilakukan oleh [1], [2], [4], [6], menunjukkan kemajuan signifikan dalam penggunaan AI-driven analytics, digital twins, dan decision support systems. Sebagai contoh, [4] mengeksplorasi penerapan deep reinforcement learning dalam konteks pemeliharaan adaptif, sementara [2] menyoroti wawasan prediktif melalui model simulasi real-time. Studi-studi ini berkontribusi terhadap perkembangan berkelanjutan prescriptive maintenance. Namun demikian, beberapa keterbatasan masih dapat ditemukan. Beberapa kerangka kerja tampak kurang menekankan pada komponen arsitektural seperti mekanisme eksekusi dan proses feedback, yang padahal penting dalam membangun sistem yang responsif dan adaptif. Selain itu, banyak upaya validasi yang masih bergantung pada simulasi atau lingkungan terkendali, sehingga memberikan wawasan terbatas mengenai performa sistem dalam real-world conditions. Kesenjangan ini juga didukung oleh hasil ekstraksi sistematis terhadap 118 artikel jurnal, di mana tren menunjukkan bahwa implementasi kapabilitas RxM masih bersifat parsial. Pola-pola tersebut mengindikasikan adanya ketidakseimbangan struktural yang menghambat pencapaian sistem RxM yang benar-benar terintegrasi dan responsif. Meskipun aspek analytics dan decision-making sering kali dibahas, mekanisme eksekusi dan feedback loop masih lemah dikembangkan atau bahkan sama sekali tidak ada. Tantangan implementasi seperti kualitas data yang buruk, kompleksitas integrasi, kurangnya interoperability, dan keterbatasan keterampilan tenaga kerja sering kali muncul sebagai hambatan. Temuan-temuan ini menekankan pentingnya pengembangan kerangka kerja yang dapat digeneralisasi dan bersifat modular, yang mampu mengakomodasi kompleksitas di dunia nyata dan memungkinkan integrasi progresif ke dalam infrastruktur yang sudah ada. Menanggapi kebutuhan tersebut, studi ini mengembangkan kerangka kerja yang dapat diskalakan dan dirancang khusus untuk lingkungan pembangkitan listrik, yang dibangun berdasarkan Systematic Literature Review (SLR) dengan panduan protokol PRISMA [7]. Kerangka ini mensintesis wawasan dari literatur ke dalam arsitektur lima layer: data collection, analytics, decision making, execution, dan feedback, yang mendorong adaptability, interoperability, dan pembelajaran berkelanjutan. Untuk mengevaluasi kekuatan dan relevansinya, dilakukan Systematic Comparative Analysis (SCA) terhadap tujuh model RxM pembandingan, guna memberikan penilaian terstruktur atas kelengkapan arsitektural dan potensi integrasinya.

Paper ini bertujuan untuk memberikan sintesis yang terstruktur dan objektif mengenai bagaimana prescriptive maintenance dikonseptualisasikan, diimplementasikan, dan divalidasi dalam konteks pembangkitan listrik. Tujuan utamanya adalah untuk menyelidiki bagaimana organisasi dapat memanfaatkan teknologi-teknologi canggih tidak hanya untuk mengantisipasi kegagalan, tetapi juga untuk mendukung real-time decision making dan continuous system adaptation. Dengan memperjelas komponen arsitektural dan kondisi operasional yang dibutuhkan untuk

implementasi RxM yang dapat diskalakan, studi ini mendorong eksplorasi lebih lanjut terhadap kerangka kerja yang mampu menyeimbangkan inovasi teknologi dengan kesiapan praktis.

RUMUSAN MASALAH

Untuk mendukung tujuan penelitian, kami merangkum investigasi kami melalui lima research question utama berikut:

1. RQ1 – Apa yang membedakan prescriptive maintenance dari pendekatan predictive dalam hal konsep dan nilai?
2. RQ2 – Teknologi pendukung apa saja yang memungkinkan implementasi prescriptive maintenance dalam pembangkitan listrik?
3. RQ3 – Komponen arsitektural apa yang mendefinisikan sebuah RxM framework yang modular dan dapat digeneralisasi?
4. RQ4 – Apa saja tantangan utama dan pertimbangan kontekstual dalam mengimplementasikan RxM?
5. RQ5 – Bagaimana kerangka kerja yang ada telah divalidasi, dan bagaimana validation dapat meningkatkan kredibilitas model yang diusulkan?

TUJUAN PENELITIAN:

Penelitian ini bertujuan untuk mengembangkan dan memvalidasi sebuah kerangka kerja prescriptive maintenance (RxM) yang modular dan dapat digeneralisasi untuk sektor pembangkitan listrik. Secara khusus, penelitian ini bertujuan untuk:

1. Mengidentifikasi perbedaan konseptual dan nilai strategis antara pendekatan prescriptive dan predictive maintenance;
2. Mengeksplorasi teknologi-teknologi utama yang memungkinkan implementasi prescriptive maintenance, termasuk Internet of Things (IoT), machine learning, digital twins, dan deep reinforcement learning;
3. Merumuskan komponen-komponen arsitektural yang mendefinisikan framework RxM yang fleksibel, modular, dan kompatibel dengan sistem industri yang sudah ada
4. Mengidentifikasi tantangan implementasi dan pertimbangan kontekstual dalam penerapan RxM di lingkungan pembangkitan listrik;
5. Melakukan validasi konseptual terhadap framework yang dikembangkan melalui *Systematic Comparative Analysis* terhadap tujuh model acuan, guna menilai kelengkapan arsitektural dan kredibilitas aplikatifnya.

KATEGORI SDGS: Penelitian ini masuk dalam kategori Sustainable Development Goals (SDGs) nomor 9: Industri, Inovasi, dan Infrastruktur. Fokus utama penelitian pada pengembangan kerangka kerja *prescriptive maintenance* di sektor pembangkitan listrik mencerminkan komitmen terhadap inovasi teknologi dan peningkatan efisiensi infrastruktur industri. Dengan memanfaatkan teknologi-teknologi canggih seperti Internet of Things, *machine learning*, dan *digital twin*, studi ini mendorong terciptanya sistem pemeliharaan yang adaptif dan berkelanjutan, yang sejalan dengan tujuan SDGs 9 untuk membangun infrastruktur yang tangguh, mendorong industrialisasi yang inklusif dan berkelanjutan, serta meningkatkan inovasi teknologi di sektor energi sebagai fondasi pertumbuhan ekonomi.

II. LITERATURE REVIEW

Sebagai upaya untuk menjawab research questions tersebut, kami melakukan systematic literature review (SLR) untuk mengeksplorasi bagaimana prescriptive maintenance telah dikaji dan diterapkan di berbagai konteks industri, dengan fokus pada penerapannya dalam sistem pembangkitan listrik. Kontribusi dari studi ini bersifat dua arah. Pertama, studi ini mensintesis wawasan mengenai bagaimana, di mana, dan mengapa RxM dapat diterapkan melalui tinjauan literatur yang berkaitan dengan pengumpulan, pemrosesan, dan penerapan data operasional melalui teknologi-teknologi pendukung. Kedua, dengan melakukan perbandingan terstruktur terhadap tujuh kerangka kerja acuan menggunakan Systematic Comparative Analysis (SCA), kami menilai koherensi arsitektural dan kesiapan praktis dari model yang diusulkan. SLR ini didasarkan pada metodologi tinjauan sistematis yang dijelaskan oleh [7], sementara analisis komparatif mengikuti panduan dari [8] dan [9]. Sejalan dengan itu, struktur paper ini diatur sebagai berikut. Bagian 2 menguraikan landasan konseptual dan pengetahuan latar belakang yang esensial untuk memahami RxM. Bagian 3

menjelaskan metodologi penelitian, termasuk strategi pencarian, kriteria seleksi, dan prosedur ekstraksi data. Bagian 4 menyajikan hasil dari SLR dan perumusan kerangka kerja yang diusulkan. Bagian 5 memperkenalkan RxM framework yang diusulkan, diikuti oleh analisis komparatif secara rinci dan implikasi praktisnya. Bagian 6 menyajikan diskusi mendalam mengenai temuan-temuan dan implikasinya, dan Bagian 7 menyimpulkan paper ini dengan merangkum kesimpulan utama serta memberikan arahan untuk penelitian dan penerapan praktis di masa mendatang.

Pemeliharaan Prescriptive: Konsep dan Karakteristik

Prescriptive maintenance merepresentasikan tahap yang lebih maju dalam pengembangan strategi pemeliharaan dengan menggabungkan metode optimization, continuous feedback, dan adaptive decision making. Berbeda dengan predictive maintenance, yang berfokus pada estimasi kemungkinan dan waktu terjadinya kegagalan, prescriptive maintenance melangkah lebih jauh dengan memanfaatkan data pasca-prognostik bersama teknik optimization seperti chance constrained models untuk mengembangkan strategi yang terarah guna meningkatkan performa sistem [10]. Keunggulan utamanya mencakup penggunaan advanced analytics untuk menghasilkan actionable insights, kemampuan merespons perubahan kondisi operasional, serta peningkatan penjadwalan yang mampu mengurangi downtime dan biaya. Kapabilitas-kapabilitas ini menjadikan prescriptive maintenance sangat bernilai dalam lingkungan yang kompleks, di mana interaksi antara berbagai komponen memerlukan pendekatan pemeliharaan yang terkoordinasi dan fleksibel.

Teknologi Pendukung Implementasi RxM

Penerapan prescriptive maintenance yang efektif dalam pembangkitan listrik dimungkinkan melalui perkembangan dan integrasi berbagai teknologi digital. Penggunaan sensor Internet of Things yang terus berkembang telah secara signifikan meningkatkan cara pemantauan peralatan dilakukan, dengan menyediakan data yang rinci dan real-time untuk mendukung pengambilan keputusan pemeliharaan yang lebih baik. Pada saat yang sama, artificial intelligence dan machine learning memainkan peran penting dalam mengidentifikasi pola dan mendeteksi ketidakaturan dalam kumpulan data berskala besar, yang memperkuat baik predictive insights maupun aksi preskriptif [3], [11]. Pengenalan teknologi digital twin menambahkan dimensi baru dengan menciptakan model virtual dari aset fisik yang mencerminkan perilaku real-time-nya. Hal ini memungkinkan simulasi operasi, deteksi anomali, dan evaluasi rencana pemeliharaan secara lebih efektif [11], [12]. Selain itu, cyber physical systems bersama dengan infrastruktur berbasis cloud-edge menyediakan daya komputasi dan responsivitas yang dibutuhkan untuk memproses data dengan cepat dan mendukung real-time decision making.

III. METODE PENELITIAN

Penelitian ini mengadopsi pendekatan eksploratif kualitatif yang didasarkan pada Systematic Literature Review (SLR) yang diselaraskan dengan protokol PRISMA 2020 [7]. Metode SLR memungkinkan identifikasi, seleksi, dan analisis studi-studi yang relevan mengenai prescriptive maintenance (RxM) secara terstruktur, sehingga memungkinkan perumusan kerangka kerja yang dapat digeneralisasi dan diterapkan dalam sistem pembangkitan listrik.

Strategi Pencarian Literatur

Tinjauan literatur dilakukan menggunakan Watase Uake, sebuah platform berbasis web yang dikembangkan di Indonesia untuk memfasilitasi systematic reviews. Alat ini, yang dapat diakses secara terbuka, terhubung langsung dengan basis data Scopus dan menyediakan fungsi penting untuk menyaring, mengorganisasi, dan menganalisis artikel ilmiah. Dengan memanfaatkan Scopus, tinjauan ini memastikan akses terhadap koleksi jurnal peer-reviewed dan high-impact yang luas. Pencarian mencakup publikasi dari tahun 2014 hingga 2024, dengan tujuan menangkap perkembangan kunci selama sepuluh tahun terakhir dalam bidang intelligent maintenance systems. Kata kunci yang digunakan mencakup kombinasi seperti: "prescriptive maintenance framework", "prescriptive digital twin", "prescriptive internet of things", "prescriptive maintenance analytics", "prescriptive maintenance energy", "prescriptive machine learning artificial intelligence", "prescriptive and predictive maintenance", "prescriptive in power plants". Kriteria inklusi dan eksklusi yang digunakan untuk mempersempit seleksi artikel dirangkum dalam Tabel 1, dan rincian serta visualisasi proses seleksi disajikan di Bagian 4.

Table 1. The inclusion and exclusion criteria

Inclusion Criteria	Exclusion Criteria
--------------------	--------------------

Inclusion Criteria	Exclusion Criteria
Published in English	Articles focusing exclusively on predictive maintenance
Indexed in Scopus Q1 journals (published between 2014 and 2024)	Studies not addressing prescriptive maintenance concepts, frameworks, or implementation
Addressed at least one RxM component (e.g., data analytics, decision making, feedback)	
Relevant to prescriptive maintenance applications, including but not limited to the industrial and energy sectors	


Ekstraksi Data dan Teknik Klasifikasi

Setiap artikel yang termasuk dalam tinjauan ini diperiksa dengan cermat, dan informasi kunci diekstraksi serta disortir menurut kategori tematik yang relevan. Proses ini mencakup pengumpulan informasi umum seperti nama penulis, tahun publikasi, negara asal, dan jenis industri yang dikaji. Ekstraksi juga difokuskan pada wawasan konseptual, khususnya bagaimana setiap studi mendefinisikan prescriptive maintenance dan membedakannya dari predictive approaches. Perhatian khusus diberikan pada bagaimana kerangka kerja disusun, terutama terkait komponen seperti data acquisition, metode analitik, proses pengambilan keputusan, execution strategies, dan feedback mechanisms. Tinjauan ini juga mengeksplorasi tantangan praktis yang dihadapi selama implementasi, serta metode yang digunakan untuk menilai efektivitas masing-masing kerangka kerja. Seluruh data yang diekstraksi dikompilasi dalam sebuah matriks terstruktur menggunakan Microsoft Excel, yang memungkinkan klasifikasi secara terorganisir ke dalam tema konseptual, teknologis, struktural, dan evaluatif. Matriks ini menjadi dasar bagi sintesis tematik yang membantu mengungkap pola umum dan wawasan penting dari studi-studi yang ditinjau. Tema-tema yang dihasilkan kemudian diselaraskan dengan lima core research questions, memastikan bahwa analisis terhubung secara jelas dengan tujuan utama dari studi ini.

Proses Pengembangan Framework Usulan

Pengembangan RxM framework yang diusulkan mengikuti metodologi yang berjenjang dan terstruktur (lihat Gambar 1). Proses dimulai dengan pencarian literatur sistematis menggunakan protokol PRISMA 2020 [7], yang memungkinkan identifikasi studi peer-reviewed berkualitas tinggi yang relevan dengan RxM dalam sektor pembangkitan listrik. Pencarian komprehensif ini menjadi landasan untuk langkah-langkah analitis selanjutnya dengan memastikan bahwa hanya studi yang relevan dan berdampak yang disertakan. Setelah itu, informasi kunci diekstraksi dan diklasifikasikan ke dalam matriks tematik. Tahap klasifikasi ini mengorganisasi literatur berdasarkan kriteria konseptual, teknologis, struktural, dan evaluatif, sehingga memudahkan penyelarasan dengan lima predefined research questions. Research questions tersebut mengeksplorasi konsep dasar dan keunggulan RxM, teknologi pendukung yang memungkinkan implementasinya, komponen struktural yang dibutuhkan untuk membangun framework yang efektif, tantangan praktis dan pertimbangan kontekstual, serta strategi validasi yang digunakan dalam model-model yang telah ada.

Fase selanjutnya melibatkan thematic synthesis, di mana pola-pola yang berulang dan wawasan dari literatur yang telah diklasifikasikan diidentifikasi dan diorganisasi sesuai dengan research questions. Sintesis ini menjadi dasar dalam merancang RxM framework, yang terdiri atas lima functional layers yang saling terkait: data collection, analytics, decision making, execution, dan feedback. Setiap layer merepresentasikan komponen penting dalam proses pemeliharaan, dengan mekanisme untuk mengintegrasikan data sensor real-time, melakukan analisis cerdas melalui machine learning, mengoptimalkan logika pengambilan keputusan menggunakan metode multi-kriteria dan reinforcement learning, mengeksekusi tugas pemeliharaan melalui simulasi digital twin dan alur kerja berbasis perangkat mobile, serta beradaptasi secara berkelanjutan melalui feedback loops. Arsitektur kerangka kerja yang modular dan dapat diskalakan ini dirancang khusus untuk mendukung implementasi di lingkungan pembangkit listrik yang kompleks dan dinamis, sekaligus memastikan kompatibilitas dengan sistem yang sudah ada seperti SCADA, CMMS, dan DCS. Langkah validasi, yang digambarkan dalam fase akhir (lihat Gambar 1), dilakukan dengan membandingkan kerangka kerja yang diusulkan dengan tujuh model acuan dari literatur, yang dipilih berdasarkan relevansi, kejelasan struktur, dan dasar empirisnya. Setiap model acuan dievaluasi berdasarkan lima core layers dalam RxM untuk mengidentifikasi area konvergensi, perbedaan, dan inovasi.



Gambar 1. Flowchart Pengembangan Usulan RxM framework.

Validasi Framework Dengan Systematic Comparative Analysis

Untuk memastikan bahwa prescriptive maintenance framework yang diusulkan memiliki kekuatan konseptual sekaligus aplikatif secara praktis, dilakukan proses validasi menggunakan systematic comparative analysis. Metode ini, yang bersifat kualitatif, sangat sesuai untuk mengevaluasi model konseptual, terutama ketika tujuannya adalah untuk mengidentifikasi kesamaan struktural dan perbedaan tematik di antara berbagai kerangka kerja [8], [9]. Dalam konteks studi ini, metode tersebut memungkinkan model yang diusulkan dievaluasi terhadap referensi-referensi yang telah mapan, sekaligus menyoroti fitur-fitur khas yang dimilikinya. Studi-studi acuan (benchmark studies) yang digunakan dalam perbandingan ini mencakup karya dari [1], [2], [4], [5], [6], [13] dan [3]. Studi-studi ini tidak dipilih secara acak, tetapi berdasarkan tiga kriteria utama. Pertama, masing-masing kerangka kerja tersebut menyajikan struktur arsitektural yang jelas dan mencakup beberapa core functional layers dari prescriptive maintenance, meskipun tidak semuanya mencakup setiap layer. Kedua, kerangka-kerangka tersebut dikembangkan dalam konteks pembangkitan listrik atau lingkungan industri lain yang memiliki kompleksitas serupa. Ketiga, mereka menunjukkan kejelasan dalam metodologi dan menawarkan pendekatan yang dapat direplikasi, yang merupakan aspek penting untuk perbandingan yang bermakna.

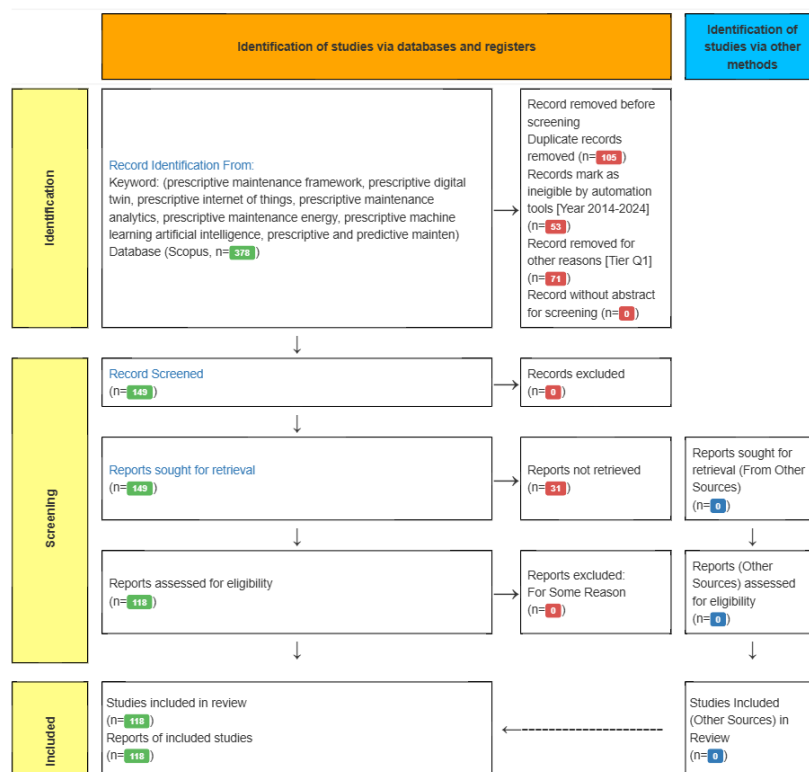
Systematic comparative analysis disusun menggunakan sistem pengkodean yang berasal dari lima core functional layers yang umum ditemukan dalam literatur: data collection, analytics, decision making, execution, dan feedback. Untuk setiap framework, penggunaan terhadap layers tersebut dinilai dan dikategorikan sebagai komprehensif, parsial, atau tidak ada. Klasifikasi ini mengikuti pendekatan evaluasi yang dijelaskan oleh [6], dan definisi layer merujuk pada karya dari [14]. Hasil dari systematic comparative analysis ini menunjukkan kesesuaian maupun perbedaan antara model yang diusulkan dengan studi acuan (lihat Tabel 3). Sebagian besar kerangka kerja yang ada mengandalkan sistem SCADA dan Internet of Things untuk data collection, namun menunjukkan variasi yang luas dalam pendekatan pada aspek analytics dan decision support. Beberapa menggunakan metode berbasis aturan atau alat predictive tradisional, sementara model yang diusulkan mencakup teknik-teknik canggih seperti deep reinforcement learning, multi criteria decision making, dan hybrid optimization. Secara khusus, kerangka kerja yang diusulkan juga memberikan struktur yang lebih jelas pada fungsi execution dan feedback dibandingkan dengan model-model pembandingan. Meskipun systematic comparative analysis efektif dalam mengidentifikasi keselarasan konseptual, keterbatasannya terletak pada tidak dilakukannya penilaian terhadap kinerja berdasarkan bukti empiris. Oleh karena itu, meskipun temuan ini mendukung ketangguhan dan orisinalitas model yang diusulkan dalam kerangka literatur yang ada, pengujian lebih lanjut dalam lingkungan operasional nyata tetap diperlukan untuk mengevaluasi kinerja praktisnya [1], [2].

IV. HASIL DAN PEMBAHASAN

HASIL PENELITIAN

Overview of Selected Literature

Bagian ini menyajikan hasil dari systematic literature review (SLR) yang dilakukan untuk menjawab lima predefined research questions (RQ1–RQ5) terkait RxM. Sebanyak 118 artikel yang diterbitkan dalam jurnal Scopus Q1 antara tahun 2014 hingga 2024 dipilih melalui prosedur penyaringan terstruktur yang dipandu oleh protokol PRISMA 2020 [7]. Proses seleksi artikel melibatkan empat tahap: identifikasi, penyaringan, penilaian kelayakan, dan inklusi akhir (lihat Gambar 2). Dari total awal 378 artikel yang diperoleh menggunakan kata kunci, sebanyak 149 artikel tersisa setelah duplikasi, sumber non-Q1, dan entri yang tidak memenuhi syarat dihapus. Setelah tahap pengambilan dokumen dan pengecekan kelayakan teks penuh, 118 artikel dinyatakan layak untuk dimasukkan dalam tinjauan. Studi-studi yang terpilih mencakup berbagai domain industri dan akademik, termasuk pembangkitan listrik, manufaktur, transportasi, dan sistem infrastruktur. Secara keseluruhan, artikel-artikel ini menyediakan dasar konseptual dan empiris untuk pengembangan RxM framework yang dapat digeneralisasi dan bersifat modular, yang akan disajikan pada bagian-bagian berikutnya.




Gambar 2. A PRISMA flow diagram dari proses seleksi

Bibliometric Characteristics

Publication Trends Over

Jumlah publikasi yang berkaitan dengan RxM telah meningkat secara signifikan selama satu dekade terakhir, dengan percepatan yang menonjol mulai tahun 2018 (lihat Gambar 3). Jumlah artikel relevan meningkat dari kurang dari 5 publikasi per tahun sebelum 2017 menjadi dua digit mulai tahun 2018, mencapai puncaknya dengan 24 artikel pada tahun 2023 dan 23 artikel pada tahun 2024. Peningkatan tajam ini, khususnya sejak tahun 2020, bertepatan dengan meluasnya adopsi transformasi digital, praktik Industry 4.0, dan integrasi artificial intelligence dalam manajemen aset dan perencanaan pemeliharaan. Tren kenaikan yang ditunjukkan dalam grafik tersebut mencerminkan meningkatnya pengakuan di kalangan akademisi dan industri terhadap prescriptive maintenance sebagai penggerak utama dalam strategi operasional yang cerdas dan berbasis data. Hal ini juga mengindikasikan bahwa bidang ini telah bergerak dari eksplorasi konseptual menuju riset yang lebih matang, terstruktur, dan berfokus pada aplikasi.



Gambar 3. The distribution of publications by year (2014–2024).

Keyword Analysis


Analisis terhadap word cloud yang dihasilkan dari artikel-artikel terpilih menunjukkan kumpulan istilah yang kaya dan beragam, mencerminkan fondasi teknologi dan prioritas strategis dari prescriptive maintenance (lihat Gambar 4). Kata kunci dominan seperti "machine learning", "prescriptive maintenance", "Internet of Things", "digital twin", dan "predictive maintenance" muncul secara menonjol di pusat visualisasi, yang mengindikasikan peran sentralnya dalam membentuk metodologi saat ini. Istilah-istilah yang berhubungan erat seperti "artificial intelligence", "anomaly detection", "health monitoring", dan "optimization" semakin menekankan kedalaman analitik dan diagnostik yang terlibat dalam sistem preskriptif. Distribusi dan frekuensi istilah juga menunjukkan bahwa prescriptive maintenance secara inheren bersifat interdisipliner, menggabungkan elemen dari data science, otomasi, dan kontrol industri. Kata kunci teknis seperti "deep learning", "decision trees", dan "mathematical programming" berdampingan dengan tujuan operasional yang lebih luas seperti "sustainability", "asset reliability", dan "condition-based monitoring". Interaksi ini menunjukkan bagaimana kapabilitas teknologi dimanfaatkan untuk memenuhi tujuan pemeliharaan yang terus berkembang di berbagai sektor.



Gambar 4. Visualisasi word cloud.

Distribution by Industrial Domain


Literatur yang ditinjau mencakup berbagai sektor, dengan porsi terbesar studi berfokus pada bidang manufaktur sebanyak 38 artikel, diikuti oleh sistem energi sebanyak 25 artikel. Hal ini menunjukkan fokus yang kuat pada industri yang sangat bergantung pada aset fisik. Bidang lain yang terwakili mencakup transportasi dengan 15 studi, 17 artikel berasal dari domain campuran atau yang tidak dispesifikasikan, serta beberapa area baru yang sedang berkembang seperti microgrids dengan 10 publikasi, layanan kesehatan sebanyak 8, dan kedirgantaraan sebanyak 6 (lihat Gambar 5). Distribusi ini menunjukkan peran prescriptive maintenance yang telah mapan dalam lingkungan industri konvensional, serta relevansinya yang semakin meningkat di bidang-bidang baru dan lebih terspesialisasi. Pie chart menggambarkan penyebaran artikel di berbagai sektor, menekankan luasnya penerapan prescriptive maintenance dalam industri dengan kebutuhan operasional yang beragam.



Gambar 5. Distribution of publications by industrial domain (2014–2024).

Distribution by Journal Outlet

Artikel-artikel yang ditinjau dalam studi ini diterbitkan di berbagai jurnal terindeks Scopus Q1, mencerminkan cakupan multidisipliner dan keterlibatan akademik yang luas dalam riset prescriptive maintenance. Dua puluh jurnal paling aktif yang berkontribusi dalam topik ini mencakup IEEE Access, Sustainability, dan Energies, masing-masing menyumbang antara enam hingga tujuh publikasi yang relevan (lihat Gambar 6). Sumber lain yang sering dikutip meliputi Sensors, Computers and Industrial Engineering, Expert Systems with Applications, dan Reliability Engineering and System Safety, yang menunjukkan dominasi perspektif teknis dan berbasis data dalam bidang ini. Distribusi ini menunjukkan bahwa diskusi mengenai prescriptive maintenance melampaui publikasi yang hanya berfokus pada pemeliharaan konvensional. Topik ini juga banyak dibahas dalam jurnal yang menekankan sistem rekayasa, artificial intelligence, smart manufacturing, dan decision support. Ragam jurnal yang terlibat menunjukkan bahwa prescriptive maintenance semakin dipandang sebagai topik penting baik di komunitas akademik maupun industri. Visibilitasnya di berbagai publikasi ini menegaskan relevansinya dalam menyelesaikan permasalahan kompleks di lingkungan operasional modern.



Gambar 6. Top 20 journal classifications of RxM publications (2014–2024).

Result of Article Extraction

Bagian ini merangkum temuan utama dari systematic literature review dengan merinci bagaimana masing-masing dari 118 artikel yang terpilih menjawab lima research questions yang menjadi panduan dalam studi ini. Pendekatan terstruktur digunakan untuk mengekstraksi informasi kunci dari setiap artikel, guna memastikan konsistensi dalam analisis serta kedalaman yang memadai untuk interpretasi tematik. Data yang diekstraksi mencakup berbagai aspek, termasuk definisi konseptual, teknologi pendukung, struktur framework, isu-isu implementasi praktis, dan metode validasi.

Analisis tematik mengungkap beberapa tren penting. Untuk research question pertama, sebanyak 70 artikel membahas konsep dasar dan keunggulan dari prescriptive maintenance, yang sering kali menekankan perkembangan strategi ini melampaui metode predictive serta kemampuannya dalam menghasilkan rekomendasi yang terarah dan optimal [15], [16]. Terkait pertanyaan kedua, 115 artikel mengkaji teknologi pendukung seperti Internet of Things, machine learning, sistem berbasis cloud, dan digital twins, yang menunjukkan kesepakatan luas mengenai fondasi teknologi yang diperlukan untuk prescriptive maintenance [3], [17]. Sebagai jawaban terhadap pertanyaan ketiga, 116 artikel membahas rancangan arsitektur prescriptive maintenance framework, dengan konsistensi penekanan pada pentingnya struktur modular yang disusun ke dalam lima key layers: data collection, analytics, decision making, execution, dan feedback. Studi-studi ini juga menyoroti perlunya kompatibilitas dengan sistem industri seperti SCADA dan CMMS [18]. Pertanyaan keempat dibahas oleh 117 studi, yang mengidentifikasi tantangan berulang seperti integrasi dengan sistem yang sudah ada, kesiapan sumber daya manusia, serta keterbatasan interpretabilitas dari artificial intelligence, namun juga mencatat peluang pada aspek asset reliability dan sustainability [6], [13]. Research question kelima, yang berkaitan dengan validasi, dijelajahi dalam 105 artikel. Meskipun banyak studi menggunakan simulasi atau metode evaluasi berbasis data [19], [20], hanya sedikit yang menerapkan perbandingan kasus ganda atau penilaian kerangka kerja yang terstruktur. Hal ini menyoroti masih adanya kesenjangan dalam validasi empiris, yang semakin menegaskan relevansi pendekatan Systematic Comparative Analysis yang digunakan dalam studi ini. Untuk memastikan kejelasan dan konsistensi, kami menyajikan ringkasan distribusi artikel berdasarkan lima research questions (lihat Tabel 2). Ringkasan ini mencakup detail bibliometrik seperti tahun publikasi, jumlah sitasi, dan pengelompokan jurnal, serta jumlah studi yang terkait dengan masing-masing pertanyaan penelitian. Rincian lengkap artikel beserta kontribusi tematiknya tersedia pada Lampiran A.

Table 2. Summary of Article Characteristics and RQ Coverage

Criteria	Summary
Total Articles	118
Publication Years	2017-2024
Average Citations	61 citations
Main Publishers	Elsevier, IEEE, MDPI, Springer, Taylor & Francis
RQ1 Coverage	70 articles
RQ2 Coverage	115 articles
RQ3 Coverage	116 articles
RQ4 Coverage	117 articles
RQ5 Coverage	105 articles

Overview Framework Usulan

Bagian ini menyajikan sebuah prescriptive maintenance framework yang dikembangkan melalui systematic review terhadap literatur, mengikuti pedoman protokol PRISMA 2020 [7]. Framework ini disusun ke dalam lima functional layers yang saling terhubung: data collection, analytics, decision making, execution, dan feedback. Kelima layer tersebut merupakan hasil dari thematic synthesis yang diambil dari berbagai studi empiris yang secara konsisten menyoroti nilai dari desain modular dan fleksibilitas dalam sistem pemeliharaan industri. Setiap layer merepresentasikan aspek operasional utama dari prescriptive maintenance. Data collection layer mengintegrasikan data real-time dan historis yang diperoleh dari perangkat seperti sensor Internet of Things, sistem SCADA, dan platform MES. Analytics layer memproses data ini menggunakan berbagai teknik machine learning, termasuk support vector machines, random forests, artificial neural networks, dan deep reinforcement learning, serta metode untuk mendeteksi anomali dan mengelola ketidakpastian. Decision-making layer mencakup alat seperti multi criteria decision analysis, sistem berbasis aturan (rule-based systems), dan teknik optimasi seperti mixed integer nonlinear programming dan genetic algorithms. Pada execution layer, framework ini memungkinkan mobile workflows, mensimulasikan tindakan melalui digital twins, dan memicu respons operasional melalui integrasi sistem. Feedback layer menyempurnakan siklus dengan mendukung pembelajaran model secara berkelanjutan dan penyesuaian sistem secara real-time. Struktur berlapis ini sengaja dirancang untuk mengatasi keterbatasan yang ditemukan dalam model-model sebelumnya, terutama dalam hal skalabilitas, kompatibilitas sistem, dan fungsionalitas real-time. Framework ini sangat cocok untuk strategi condition-based maintenance di sektor pembangkitan listrik dan dapat diintegrasikan dengan sistem yang sudah ada seperti distributed control systems, computerized maintenance management systems, dan platform SCADA. Framework ini mengacu pada wawasan dari beberapa studi empiris, termasuk dari studi [1], [2], [3], [4], [5], [6], [13]. Masing-masing studi ini berkontribusi terhadap integritas arsitektural dari framework yang dikembangkan. Sebagai hasilnya, model yang diusulkan ini menawarkan solusi yang fleksibel dan dapat diterapkan secara luas, khususnya dalam industri yang kompleks dan bergantung pada aset, terutama di sektor energi.

Validasi Komparatif Framework

Sebelum melakukan comparative validation, dilakukan proses seleksi yang cermat untuk mengidentifikasi studi acuan (benchmark) yang sesuai. Tujuannya adalah menemukan prescriptive maintenance frameworks yang telah diuji atau diterapkan dalam lingkungan industri nyata dan dapat dijadikan referensi yang andal untuk perbandingan terstruktur. Pemilihan ini didasarkan pada systematic review terhadap 118 artikel yang relevan, dengan mempertimbangkan tiga kriteria utama: pertama, adanya implementasi empiris melalui simulasi, uji lapangan, atau penerapan dalam operasi aktual; kedua, mencakup functional layers yang menjadi inti dari prescriptive maintenance frameworks; dan ketiga, relevansi domain industrinya, dengan preferensi terhadap sektor-sektor yang berkaitan erat dengan pembangkitan listrik, namun tidak terbatas pada itu. Berdasarkan kriteria tersebut, tujuh studi dipilih untuk mendukung comparative validation. Studi-studi tersebut meliputi karya dari [1], [2], [3], [4], [5], [6], [13]. Masing-masing studi ini telah diterapkan atau dievaluasi dalam lingkungan nyata maupun simulasi, di sektor seperti cyber physical systems, kedirgantaraan, distribusi tenaga listrik, dan otomasi industri. Comparative analysis disusun

berdasarkan lima core layers yang berasal dari framework yang diusulkan: data collection, analytics, decision making, execution, dan feedback (lihat Tabel 3). Layers ini digunakan untuk meninjau masing-masing studi benchmark dalam hal kekuatan bersama, area yang masih kurang dikembangkan, dan kontribusi unik yang terdapat dalam model yang diusulkan.

Table 3. Systematic Comparative Analysis (SCA) of RxM frameworks

Layer	Proposed Framework	[1]	[5]	[3]	[4]	[2]	[13]	[6]
Data Collection	IoT, SCADA, MES, real-time + historical, cloud-edge hybrid.	Relies on IoT sensors for monitoring key variables.	Relies on sensor networks within a cyber physical system.	Relies on data from IoT sensors.	Relies on SCADA and IoT integration.	Relies on data from IoT sensors.	Relies on SCADA and sensor-based data from wind turbines.	Relies on IoT-based sensor readings.
Analytics	ML (SVM, RF, ANN, DRL), anomaly detection, uncertainty quantification.	Uses machine learning for fault detection and prognostics.	Combines Random Forest and Gaussian Mixture Models for anomaly detection.	Uses DRL and transformer models to extract optimal policies.	Uses deep reinforcement learning (TranDRL) for decision-making.	Applies virtual reality and simulation-based analytics via digital twins.	Uses rule-based logic and statistical trend analysis.	Uses a learning-based model calibrated through sensor data.
Decision Making	Optimization (MINLP, GA), rule-based systems, MCDM (AHP, TOPSIS), dynamic DRL.	Rule-Based System and Decision Support System.	Decision Support System using a machine learning model.	Uses an optimization engine to recommend maintenance policies.	Uses DRL optimization for combinatorial action spaces.	Applies OODA loop integrated with simulation and ranking logic.	No structured decision layer defined.	Uses desirability functions to optimize prescriptive outputs.
Execution	Digital twin validation, mobile workflow integration.	No structured execution layer defined.	No structured execution layer defined.	No structured execution layer defined.	No structured execution layer defined.	The framework allows digital twin-driven simulation triggering.	No structured execution layer defined.	No structured execution layer defined.
Feedback	Continuous learning, model recalibration, real-time update.	No structured feedback layer defined.	No structured feedback layer defined.	Feedback-driven policy updates through DRL.	Feedback loop via reinforcement learning model.	Feedback enabled through simulation discrepancies.	Partial feedback based on alarms.	Continuous feedback loop through sensor recalibration.

Model-model yang ada menunjukkan performa yang kuat dalam pengumpulan data, namun sebagian besar hanya bergantung pada sumber seperti perangkat IoT atau sistem SCADA. Framework yang diusulkan membangun dari dasar ini dengan menggabungkan data real-time dan historis dalam lingkungan komputasi cloud dan edge, yang meningkatkan kemampuannya untuk merespons secara efektif terhadap kondisi operasional yang berubah-ubah. Pada komponen analytics, sebagian besar studi benchmark menerapkan teknik machine learning konvensional atau secara spesifik berfokus pada deep reinforcement learning. Framework yang diperkenalkan dalam studi ini memperluas metode tersebut dengan mengintegrasikan statistical learning, deep learning, dan pendekatan yang memperhitungkan ketidakpastian, sehingga sistem mampu beradaptasi dan memberikan insight yang andal bahkan di bawah kondisi data yang fluktuatif dan penuh gangguan. Untuk decision making, beberapa model mengadopsi logika berbasis aturan (rule-based logic) atau metode optimasi, sebagaimana ditunjukkan dalam studi oleh [4], [5], [6]. Berbeda dengan

upaya-upaya sebelumnya, framework yang diusulkan menggabungkan berbagai alat pengambilan keputusan seperti multi criteria evaluation, metaheuristic algorithms, dan reinforcement learning ke dalam satu layer terintegrasi yang mendukung keputusan yang lebih fleksibel dan berbasis informasi. Kesenjangan yang paling mencolok di antara model-model benchmark terdapat pada komponen execution dan feedback. Studi seperti yang dilakukan oleh [4], [5], [13] tidak secara eksplisit membahas layer-layer ini. Sebaliknya, framework yang diusulkan mengintegrasikan simulasi melalui digital twins, eksekusi tugas yang didukung mobile, serta continuous feedback untuk model recalibration, menghasilkan sistem yang menutup siklus dan mendukung pembelajaran real-time. Meskipun masing-masing model referensi memberikan kontribusi yang berharga, tidak ada satupun yang menyediakan struktur terintegrasi secara penuh yang mencakup seluruh layers dari prescriptive maintenance dengan fleksibilitas modular dan continuous feedback. Framework yang diusulkan mengisi kesenjangan ini dengan memperkenalkan arsitektur yang lengkap dan adaptif untuk mendukung strategi pemeliharaan tingkat lanjut, khususnya dalam konteks kompleks seperti pembangkitan listrik.

Deskripsi Fungsional Layer dan Integrasi Visual

Bagian ini menjelaskan lima fundamental layers dari framework prescriptive maintenance (RxM) yang diusulkan, dengan menyelaraskan masing-masing layer dalam alur terstruktur (lihat Gambar 7). Gambar tersebut mengilustrasikan bagaimana input, teknik analitik, dan output diorganisasi dalam layer-layer yang saling terhubung, membentuk siklus operasional berkelanjutan yang mentransformasi raw data menjadi insight yang dapat dieksekusi serta pembelajaran adaptif. Layer pertama (1.1–1.3 pada Gambar 7) memulai proses dengan menggabungkan data dari sensor IoT, sistem SCADA, platform MES, dan log pemeliharaan historis. Kombinasi ini dirancang untuk mengintegrasikan informasi real-time dan historis ke dalam satu aliran input yang terpadu (1.3), yang didukung oleh infrastruktur komputasi cloud dan edge hibrida. Berbeda dengan model dari [6], [13] yang berfokus terutama pada SCADA, atau dari [5] dan [1] yang menekankan pada jaringan sensor, framework ini mengkonsolidasikan kedua dimensi tersebut pada tingkat input. Seperti yang divisualisasikan dalam layer kedua (2.1–2.3 pada Gambar 7), data yang dikumpulkan diproses melalui tahap cleansing, feature extraction, dan anomaly detection (2.1), dilanjutkan dengan pemodelan prediktif menggunakan berbagai algoritma machine learning (2.2), termasuk support vector machines, random forests, artificial neural networks, dan deep reinforcement learning. Output dari tahap ini berupa predictive insight, seperti perkiraan kegagalan dan estimasi sisa masa pakai (remaining useful life) (2.3). Meskipun studi seperti [3], [4] menyoroti reinforcement learning tingkat lanjut, dan [2] berfokus pada pemodelan digital twin, hanya sedikit yang mengintegrasikan komponen-komponen ini ke dalam mesin analytics yang kohesif dan mendukung pembelajaran statis maupun adaptif sebagaimana dilakukan dalam framework ini. Layer ketiga (3.1–3.3 pada Gambar 7) menerjemahkan predictive insights menjadi rekomendasi pemeliharaan yang konkret. Hal ini dicapai melalui kombinasi metode optimasi (seperti mixed integer nonlinear programming dan genetic algorithms), alat pengambilan keputusan multi-kriteria (seperti AHP dan TOPSIS), dan adaptasi kebijakan berbasis reinforcement learning (3.2).

Rekomendasi yang dihasilkan (3.3) bersifat kontekstual dan ditargetkan secara operasional. Sebaliknya, [5] dan [1] menggunakan logika berbasis aturan yang tetap (fixed rule-based logic), dan [4] hanya fokus pada DRL. [2] mengintegrasikan simulasi namun belum menggabungkan pendekatan multi-metode dalam pengambilan keputusan. Layer keempat (4.1–4.3 pada Gambar 7) berfokus pada pelaksanaan tindakan yang telah diresepkan. Rekomendasi pemeliharaan (4.1) divalidasi melalui simulasi digital twin dan dijalankan melalui platform mobile atau diintegrasikan ke dalam sistem pemeliharaan seperti CMMS (4.2). Hasilnya adalah aktivitas pemeliharaan yang dapat ditelusuri dan dieksekusi secara real-time (4.3). Layer ini menjawab kekosongan yang ada di banyak model sebelumnya, termasuk dari [4], [5], [13], yang tidak menjelaskan mekanisme eksekusi secara rinci. Meskipun [2] menggabungkan umpan balik simulasi, namun belum langsung terhubung dengan alur kerja eksekusi tingkat mobile atau enterprise. Layer terakhir (5.1–5.3 pada Gambar 7) memungkinkan peningkatan berkelanjutan melalui pengumpulan hasil tindakan yang telah dieksekusi kembali ke dalam model analytics. Ini dilakukan melalui pemantauan kinerja real-time, recalibration, dan retraining (5.2), yang memungkinkan framework beradaptasi dengan kondisi yang terus berkembang. Feedback loop (5.3) memastikan bahwa pembelajaran diintegrasikan kembali ke dalam mesin analitik (khususnya Layer 2.2), sehingga menutup siklus. Sementara structured feedback jarang ditemukan dalam model-model terdahulu, hanya beberapa studi seperti [3], [4], [6] yang membahasnya secara menyeluruh. Studi lainnya, seperti [5], [13], tidak memiliki kapabilitas ini. Setiap layer berkontribusi pada proses closed-loop yang

mencakup data acquisition, analysis, decision generation, execution, dan penyempurnaan berbasis feedback. Berbasis pada bukti empiris dan diperkuat oleh teknologi digital twin serta pembelajaran adaptif, framework ini menawarkan jalur terintegrasi untuk mencapai prescriptive maintenance yang efektif di lingkungan industri yang kompleks.



Gambar 7. Proposed prescriptive maintenance (RxM) framework.

Implementasi Praktis Pada Konteks Pembangkit Listrik

Framework prescriptive maintenance yang diperkenalkan dalam studi ini dirancang dengan mempertimbangkan aspek adaptabilitas, sehingga cocok diterapkan pada berbagai sistem pembangkit listrik, termasuk pembangkit termal, hidroelektrik, angin, dan surya. Struktur modularnya mengintegrasikan pemantauan langsung (live monitoring), advanced analytics, dan continuous feedback loop, memungkinkan framework ini berfungsi secara efektif baik di lingkungan terpusat maupun terdistribusi. Pada pembangkit listrik termal, penggabungan keluaran SCADA dengan catatan historis dari platform MES dan log aset mendukung deteksi dini atas ketidakteraturan serta memungkinkan penjadwalan yang lebih akurat untuk komponen kritis seperti boiler, turbin, dan sistem feedwater. Pendekatan yang diusulkan oleh [5] menunjukkan bagaimana cyber physical systems yang mengandalkan pemantauan berbasis sensor dan logika keputusan yang dioptimalkan dapat diimplementasikan dalam operasi energi skala besar. Dalam kerangka ini, penggunaan rule-based reasoning dan multi-criteria analysis membantu operator pembangkit memprioritaskan intervensi berdasarkan kondisi peralatan dan urgensi operasional. Dalam konteks pembangkit listrik tenaga air, alat simulasi memainkan peran penting dalam mengamati keausan komponen, variasi tekanan, dan perilaku aliran. [2] menyoroti kegunaan platform digital twin untuk melakukan simulasi real-time dan memvalidasi strategi pemeliharaan dalam lingkungan fluida dinamis. Mekanisme eksekusi dari framework ini, yang mendukung akses mobile dan integrasi CMMS, sangat berguna untuk lokasi pembangkit air yang terpencil atau sulit dijangkau. Untuk aplikasi pembangkit tenaga angin dan surya, di mana komponen tersebar secara geografis dan intervensi manual sering kali terbatas, kemampuan untuk memproses data di edge dan melakukan diagnostik jarak jauh menjadi hal yang esensial. Seperti yang ditunjukkan dalam studi oleh [6] dan [13], bahkan di lokasi dengan infrastruktur sensor yang terbatas atau

konektivitas yang tidak stabil, sistem yang ditenagai oleh IoT dan SCADA tetap dapat menghasilkan operational insights yang berharga.

Komponen feedback dari framework, yang mendukung ongoing learning dan dynamic recalibration, meningkatkan reliability sistem dengan memungkinkan adaptasi real-time terhadap kondisi yang berubah. Bukti tambahan dari [1] menunjukkan bahwa model prescriptive maintenance dapat diintegrasikan dengan perencanaan logistik dan inventaris, yang sangat penting untuk pengelolaan spare part dan koordinasi waktu pemeliharaan. Selain itu, studi oleh [4] dan [3] mengonfirmasi efektivitas deep reinforcement learning dalam mengadaptasi kebijakan pengambilan keputusan dalam kondisi ketidakpastian, pendekatan yang diperluas oleh framework ini ke berbagai jenis aset. Dari sisi implementasi, execution layer telah disusun untuk kompatibel dengan platform enterprise asset management yang banyak digunakan, termasuk IBM Maximo dan solusi CMMS lainnya, dengan menggunakan protokol seperti OPC UA. Hal ini memastikan bahwa framework tidak hanya layak secara operasional tetapi juga dapat diukur. Seperti yang dikemukakan oleh [6] dan [21], kurangnya indikator kinerja standar untuk prescriptive maintenance masih menjadi tantangan signifikan. Oleh karena itu, membangun titik-titik integrasi juga membantu dalam mengevaluasi bagaimana sistem bekerja di lingkungan nyata melalui uji coba berskala pilot. Framework yang diusulkan ini menggabungkan architectural insights dari berbagai studi ke dalam suatu struktur yang siap diterapkan secara praktis.

PEMBAHASAN

Bagian ini menyajikan diskusi komprehensif yang merangkum wawasan utama yang diperoleh dari systematic literature review dan proses validasi terhadap prescriptive maintenance framework yang diusulkan, sebagaimana kaitannya dengan lima pertanyaan penelitian. Diskusi ini memberikan konteks untuk masing-masing pertanyaan sekaligus mengeksplorasi signifikansi yang lebih luas, khususnya dalam konteks pembangkit listrik. Setiap bagian dari diskusi ini dikaitkan secara langsung dengan satu pertanyaan penelitian, dan memperluas pembahasan mengenai kontribusi teoretis, relevansi praktis, serta kesenjangan yang masih ada sebagaimana teridentifikasi dalam literatur yang telah ditelaah.

Konsep Utama dari RxM (RQ1)

RQ1 berfokus pada pemahaman konsep inti dari prescriptive maintenance dan bagaimana pendekatan ini berbeda dari predictive maintenance (PdM), termasuk manfaat strategis yang dihasilkan dari penerapannya. Perkembangan strategi pemeliharaan mencerminkan pergeseran bertahap dari pendekatan reaktif menuju decision making yang proaktif. RxM mewakili fase paling maju dalam perkembangan ini, setelah paradigma korektif, preventif, dan prediktif. Sementara PdM berfokus pada antisipasi kegagalan peralatan menggunakan data historis dan real time, pendekatan tersebut umumnya berhenti pada tahap peramalan. RxM memperluas kemampuan ini dengan memberikan rekomendasi tindakan spesifik yang sebaiknya dilakukan untuk mengurangi atau mencegah kegagalan, dengan mempertimbangkan kendala operasional dan tujuan strategis. Secara konseptual, RxM menekankan peran decision support dalam kegiatan pemeliharaan. PdM menjawab pertanyaan “apa yang mungkin gagal dan kapan”, sedangkan RxM menjawab “apa yang seharusnya dilakukan, bagaimana melakukannya, dan dalam kondisi apa”. Perbedaan ini bukan hanya bersifat fungsional tetapi juga struktural. Sistem RxM menggabungkan sensor real time, analytics, dan model optimisasi untuk menghasilkan rekomendasi yang sensitif terhadap konteks. Studi acuan seperti [5] dan [4] menunjukkan penerapan di mana algoritma cerdas menghasilkan keluaran preskriptif yang membimbing atau mengotomatisasi intervensi pemeliharaan. Manfaat RxM yang tercatat dalam literatur mencakup peningkatan asset reliability, pengurangan waktu henti tak terencana, prioritas tugas yang lebih efektif, optimalisasi penggunaan inventaris, dan keselarasan yang lebih erat antara operasi pemeliharaan dan tujuan produksi. [6] dan [2] menekankan bahwa pendekatan preskriptif dapat meningkatkan situational decision making dalam kondisi yang penuh ketidakpastian, sementara studi seperti [4] menunjukkan bahwa sistem dengan feedback loop mendukung pembelajaran bertahap dan kemampuan adaptasi sistem yang umumnya tidak dimiliki oleh strategi prediktif semata.

Teknologi Pendukung Implementasi RxM (RQ2)

RQ2 berfokus pada identifikasi teknologi utama yang mendukung implementasi RxM. Literatur dan studi acuan secara konsisten menyoroti pentingnya beberapa enabling technologies, yang masing-masing berkontribusi pada fase spesifik dalam proses RxM. Internet of Things (IoT) memungkinkan pemantauan real time dengan menghubungkan

sensor dan aktuator pada berbagai aset, sehingga memungkinkan pengambilan data secara terus menerus terhadap variabel seperti getaran, suhu, dan beban. Studi seperti [6] dan [1] menunjukkan bagaimana platform IoT membentuk fondasi sistem pemeliharaan yang responsif. Machine Learning (ML), khususnya model terawasi seperti Support Vector Machines (SVM), Random Forest (RF), dan Artificial Neural Networks (ANN), secara luas digunakan untuk mendeteksi anomali dan memprediksi kegagalan. Dalam pengaturan yang lebih maju, Deep Reinforcement Learning (DRL) diterapkan untuk mempelajari kebijakan pemeliharaan yang optimal melalui interaksi berulang dengan kondisi sistem yang berubah, sebagaimana ditunjukkan oleh [4] dan [3]. Digital twins melengkapi teknologi teknologi tersebut dengan mensimulasikan perilaku aset dan memvalidasi tindakan preskriptif dalam lingkungan virtual. [2], misalnya, mengilustrasikan bagaimana simulasi digital twin dapat mendukung diagnostik berbasis model dan pengujian skenario sebelum diterapkan secara langsung. Secara kolektif, teknologi teknologi ini memungkinkan terbentuknya sistem pemeliharaan yang cerdas dan adaptif. Peran masing masing teknologi ini akan dijelaskan lebih lanjut pada bagian berikutnya yang membahas struktur arsitektural yang diperlukan untuk mengintegrasikan semuanya secara efektif.

Structural Components of a Generalizable RxM Framework (RQ3)

RQ3 membahas elemen struktural yang dibutuhkan untuk membangun framework RxM yang bersifat general dan dapat diterapkan secara luas, khususnya dalam konteks pembangkitan listrik. Systematic literature review dan systematic comparative analysis mengungkapkan pola arsitektural berulang yang dibangun di atas lima functional layers yang saling terkait, yaitu: data collection, analytics, decision making, execution, dan feedback. Kelima lapisan ini mencerminkan aliran informasi dan kontrol yang khas dalam sistem RxM, dimulai dari akuisisi data real time dan kontekstual dari platform IoT dan SCADA, dilanjutkan dengan pemrosesan data menggunakan model machine learning. Decision making dibangun berdasarkan hasil analytics melalui teknik optimasi atau logika berbasis aturan, yang kemudian dioperasikan melalui sistem execution seperti CMMS dan divalidasi melalui feedback loops yang mendukung pembelajaran berkelanjutan. Studi acuan seperti [2], [4], [5] menunjukkan cakupan yang bervariasi terhadap lapisan-lapisan ini, di mana sebagian besar menekankan pada data dan analytics namun kurang membahas aspek execution dan feedback. Kesenjangan ini menegaskan pentingnya sebuah model struktural yang lengkap, yang tidak hanya memproses data, tetapi juga menghubungkan hasil decision making dengan tindakan operasional dan mekanisme pembelajaran. Struktur lima lapisan yang diformalkan dalam studi ini menawarkan fondasi modular untuk mengadaptasi RxM di berbagai tipe aset dan kompleksitas sistem. Pemisahan fungsi di tiap lapisan memungkinkan organisasi untuk menerapkan framework ini secara bertahap, serta meningkatkan interoperabilitas dengan sistem yang telah ada seperti SCADA, DCS, dan CMMS. Dengan demikian, framework ini tidak diposisikan sebagai model yang kaku, melainkan sebagai panduan fleksibel yang mendukung standarisasi sekaligus adaptasi lokal di lingkungan pembangkit listrik.

Implementation Challenges and Emerging Opportunities (RQ4)

RQ4 berfokus pada identifikasi tantangan utama dan peluang yang terkait dengan penerapan RxM di lingkungan operasional. Hasil tinjauan literatur dan studi perbandingan menunjukkan bahwa meskipun RxM menawarkan kapabilitas yang menjanjikan, adopsinya sangat dipengaruhi oleh kendala teknis dan organisasi. Di antara tantangan teknis yang paling umum adalah masalah interoperabilitas data. Mengintegrasikan data dari berbagai sumber heterogen seperti sistem SCADA lama, sensor IoT, dan platform CMMS sering kali membutuhkan middleware atau API yang disesuaikan. Selain itu, keterbatasan infrastruktur, terutama pada fasilitas yang sudah tua, dapat membatasi penerapan teknologi baru seperti digital twin atau cloud edge computing. Masalah lain yang menonjol adalah keterbatasan dalam explainability model AI, yang dapat mengurangi tingkat kepercayaan operator terhadap rekomendasi yang dihasilkan secara otomatis. Dari sisi organisasi, tantangan yang sering muncul meliputi kesenjangan keterampilan, ketidaksesuaian antar fungsi, serta tidak adanya manajemen perubahan yang terstruktur. Adopsi RxM yang berhasil memerlukan koordinasi yang erat antara tim pemeliharaan, departemen TI, dan manajemen pembangkit. Studi seperti [1] dan [2] menekankan pentingnya penerapan bertahap dan desain sistem yang berorientasi pada pengguna. Meskipun demikian, sejumlah peluang kini mulai terbuka. Arsitektur modular seperti yang diusulkan dalam studi ini memungkinkan kompatibilitas dengan sistem yang sudah ada dan memungkinkan penerapan bertahap tanpa harus merombak sistem secara keseluruhan. Perkembangan dalam explainable AI (XAI)

meningkatkan transparansi dalam pengambilan keputusan berbasis model, sementara kemajuan dalam sensor berbiaya rendah dan komputasi berbasis edge menjadikan RxM semakin mudah diakses, bahkan oleh fasilitas dengan sumber daya terbatas. Perkembangan ini menunjukkan bahwa meskipun implementasinya memerlukan perencanaan yang cermat, kondisi untuk adopsi RxM yang lebih luas khususnya di sektor pembangkitan listrik semakin mendukung. Seiring dengan semakin banyaknya proyek percontohan dan uji coba industri, pembelajaran bersama dan standar praktis kemungkinan besar akan mengikuti.

Validation and Practical Credibility of RxM Frameworks (RQ5)

RQ5 membahas bagaimana studi sebelumnya memvalidasi kerangka prescriptive maintenance (RxM) dan bagaimana proses ini berkontribusi pada kredibilitas model yang diusulkan dalam penelitian ini. Tinjauan menunjukkan bahwa sebagian besar studi RxM yang ada masih bersifat konseptual, dengan upaya validasi yang umumnya terbatas pada simulasi, uji prototipe, atau perbandingan dengan solusi teknologi yang sedang digunakan. Validasi berbasis lapangan masih relatif jarang dilakukan, sering kali karena keterbatasan operasional di lingkungan industri. Dalam penelitian ini, kerangka yang diusulkan dievaluasi menggunakan systematic comparative analysis, yang menelaah kesesuaian struktural dan fungsional dengan tujuh model RxM berbasis empiris. Perbandingan difokuskan pada keberadaan lima lapisan inti, yaitu data collection, analytics, decision making, execution, dan feedback, serta teknologi pendukung seperti IoT, machine learning, deep reinforcement learning, dan digital twins. Meskipun tidak menggantikan uji coba lapangan, metode ini memungkinkan refleksi terstruktur mengenai kelengkapan konsep dan kesiapan fungsional. Hasil dari systematic comparative analysis menunjukkan bahwa meskipun banyak model membahas aspek data dan analytics, mereka sering kali tidak memiliki mekanisme formal untuk execution dan feedback. Sebaliknya, kerangka yang diusulkan dalam studi ini mengintegrasikan komponen tersebut secara eksplisit, sehingga lebih lengkap dan adaptif. Kedalaman analisis ini meningkatkan konsistensi internal kerangka dan menyediakan titik acuan untuk upaya implementasi di masa depan. Namun demikian, validasi lebih lanjut tetap dibutuhkan. Penelitian mendatang sebaiknya mencakup pengujian di lingkungan pembangkit listrik yang beroperasi, disertai evaluasi kinerja, analisis biaya dan manfaat, serta umpan balik dari para praktisi. Upaya ini penting untuk menunjukkan tidak hanya ketepatan konseptual tetapi juga kelayakan praktis dalam kondisi nyata. Meskipun kerangka yang diusulkan menunjukkan keselarasan dengan pola arsitektur yang ada dan menanggapi kesenjangan yang teridentifikasi dalam studi perbandingan, validasinya masih bersifat konseptual. Temuan dari analisis ini menjadi dasar untuk eksplorasi lanjutan, tetapi belum dapat menggantikan pengujian di lapangan. Implikasi yang lebih luas, keterbatasan, dan arahan penelitian masa depan dibahas pada bagian penutup setelah ini.

V. SIMPULAN

Studi ini bertujuan untuk memperluas pemahaman dan penerapan praktis prescriptive maintenance (RxM) di sektor pembangkit listrik dengan melakukan systematic literature review terhadap 118 artikel berkualitas tinggi yang diterbitkan antara tahun 2014 hingga 2024. Melalui lima research question yang terdefinisi dengan baik, studi ini menelaah dasar konseptual dari RxM, teknologi pendukung, struktur arsitektural, tantangan implementasi, serta strategi validasi. Temuan tersebut disintesis ke dalam sebuah kerangka modular yang terdiri dari lima lapisan, yaitu data collection, analytics, decision making, execution, dan feedback. Kerangka ini dirancang untuk menghadapi kompleksitas lingkungan operasional di pembangkit listrik, dengan menawarkan solusi yang dapat diskalakan dan disesuaikan untuk transisi dari strategi predictive menuju prescriptive maintenance. Hasil penelitian menunjukkan bahwa RxM merupakan evolusi penting melampaui predictive maintenance, karena memungkinkan sistem tidak hanya mengantisipasi kegagalan peralatan tetapi juga merekomendasikan tindakan yang spesifik dan sesuai dengan konteks. Kemampuan ini bergantung pada integrasi berbagai teknologi seperti sensor IoT, algoritma machine learning, digital twins, dan deep reinforcement learning. Setiap teknologi tersebut memiliki peran tersendiri dalam siklus pemeliharaan, mulai dari penginderaan dan akuisisi data, hingga simulasi, analisis secara real time, dan umpan balik yang adaptif. Ketika dikombinasikan secara sistematis, teknologi-teknologi ini membentuk platform yang kuat untuk peningkatan berkelanjutan, efisiensi operasional yang lebih tinggi, dan keandalan aset yang ditingkatkan. Kerangka yang diusulkan merujuk pada studi acuan, selaras dengan model yang telah ada namun juga menjawab aspek yang sering diabaikan seperti mekanisme pelaksanaan dan pembelajaran berbasis umpan balik, sehingga meningkatkan kedalaman teoritis sekaligus kesiapan implementasi praktis.

Namun, penerapan RxM dalam lingkungan industri menghadirkan sejumlah tantangan. Studi ini mengidentifikasi hambatan utama, termasuk keterbatasan teknis terkait interoperabilitas sistem, ketidakpastian terhadap keandalan rekomendasi yang dihasilkan oleh kecerdasan buatan, kesenjangan dalam kesiapan organisasi, serta ketidaksesuaian keterampilan di antara personel pemeliharaan. Tantangan ini menekankan pentingnya arsitektur yang fleksibel dan strategi implementasi bertahap. Modularitas, transparansi dalam logika pengambilan keputusan, serta kompatibilitas dengan platform yang sudah ada seperti SCADA dan CMMS menjadi elemen penting untuk penerapan yang praktis. Meskipun literatur yang ditinjau mencakup berbagai kerangka kerja konseptual dan validasi berbasis simulasi, masih terdapat kekurangan bukti dari aplikasi langsung di lapangan. Hal ini menyoroti kesenjangan antara pengembangan akademik dan penerapan operasional. Untuk mengatasi kesenjangan ini, penelitian di masa depan perlu difokuskan pada penerapan kerangka RxM yang diusulkan di lingkungan pembangkit listrik yang sedang beroperasi, guna mengevaluasi kinerjanya dalam kondisi nyata. Evaluasi tersebut mencakup konsistensi sistem, akurasi rekomendasi, tingkat penerimaan pengguna, serta responsivitas terhadap variabel operasional yang berubah. Selain itu, perlu dikembangkan metrik standar untuk mengevaluasi sistem prescriptive maintenance. Metrik ini sebaiknya tidak hanya mengukur akurasi prediktif, tetapi juga mencakup kualitas, dampak, dan ketepatan waktu dari intervensi yang direkomendasikan. Indikator semacam ini tidak hanya memungkinkan evaluasi yang efektif, tetapi juga menyediakan dasar bagi perbaikan berkelanjutan. Lebih lanjut, penerapan metode explainable artificial intelligence sangat penting untuk meningkatkan kepercayaan pengguna, terutama karena model yang semakin kompleks seperti deep reinforcement learning mulai banyak digunakan.

Kemampuan untuk menafsirkan dan menelusuri alasan di balik saran sistem sangat penting untuk memastikan kolaborasi yang efektif antara manusia dan sistem cerdas dalam perencanaan pemeliharaan. Selain itu, studi di masa depan perlu menyelidiki aspek sosial dan organisasi dari adopsi RxM, termasuk pelatihan tenaga kerja, koordinasi lintas departemen, dan manajemen perubahan yang terstruktur. Seiring dengan kemajuan industri menuju prinsip-prinsip Industry 5.0 yang menekankan pengembangan teknologi yang berpusat pada manusia dan berkelanjutan, sistem prescriptive maintenance juga harus berkembang untuk mendukung integrasi seimbang antara teknologi analitik dan keahlian manusia. Perubahan ini memerlukan penelitian yang mencakup tidak hanya faktor teknologi dan ekonomi, tetapi juga pertimbangan etika, regulasi, serta aspek terkait tenaga kerja. Secara keseluruhan, wawasan ini memperkuat signifikansi luas dari studi ini yang menawarkan pandangan komprehensif dan integratif tentang prescriptive maintenance dalam konteks pembangkitan listrik.

UCAPAN TERIMA KASIH

Dengan penuh rasa hormat dan syukur, penulis mengucapkan terima kasih yang sebesar-besarnya kepada Ibu Rita Ambarwati, S.E., M.M., selaku dosen pembimbing atas bimbingan, arahan, dan motivasi yang telah diberikan selama proses penulisan penelitian ini. Ucapan terima kasih juga disampaikan kepada seluruh dosen penguji dan sivitas akademika Program Studi Magister Manajemen Universitas Muhammadiyah Sidoarjo atas ilmu dan dukungannya. Tidak lupa, penulis menghaturkan terima kasih kepada keluarga dan rekan-rekan yang telah memberikan semangat, doa, serta dukungan moral dan material yang sangat berarti hingga penelitian ini dapat terselesaikan dengan baik.

Lampiran A. Detailed Mapping of Extracted Articles

Lampiran ini menyajikan pemetaan komprehensif terhadap 118 artikel yang dianalisis dalam studi ini. Setiap entri mencakup nama penulis, penerbit, jumlah sitasi, serta kontribusi tematiknya terhadap lima pertanyaan riset (RQ1–RQ5). Pemetaan dilakukan menggunakan kerangka ekstraksi yang terstruktur, sehingga menjamin konsistensi dan keterlacakan dalam keseluruhan proses systematic literature review (SLR). Lampiran ini menjadi landasan empiris bagi analisis bibliometrik dan sintesis tematik yang dibahas dalam Bagian 4.

Table A.1. synthesized distribution of articles contributing to each RQ

Author	Publisher	Citation	RQ1	RQ2	RQ3	RQ4	RQ5
[13]	MDPI	47	✓	✓	✓	✓	✓
[22]	Elsevier	46		✓	✓	✓	✓
[16]	Elsevier	104	✓	✓	✓	✓	✓
[15]	Elsevier	7	✓	✓	✓	✓	✓

Author	Publisher	Citation	RQ1	RQ2	RQ3	RQ4	RQ5
[23]	Elsevier	9	✓	✓	✓	✓	✓
[24]	AIChE	17	✓	✓	✓	✓	✓
[25]	IEEE	11	✓	✓	✓	✓	✓
[26]	Elsevier	102	✓	✓	✓	✓	✓
[27]	Taylor & Francis	4	✓	✓	✓	✓	✓
[28]	Elsevier	144	✓	✓	✓	✓	✓
[29]	IOS Pres	15		✓	✓	✓	✓
[17]	MDPI	37	✓	✓	✓	✓	✓
[30]	Elsevier	13	✓	✓	✓	✓	✓
[31]	Elsevier	1	✓	✓	✓	✓	✓
[32]	WILEY	19		✓	✓	✓	✓
[33]	Elsevier	4	✓	✓	✓	✓	✓
[6]	IEEE	11	✓	✓	✓	✓	✓
[34]	Elsevier	9	✓	✓	✓	✓	✓
[35]	Elsevier	18		✓	✓	✓	
[36]	Elsevier	11	✓	✓	✓	✓	✓
[37]	Elsevier	78		✓	✓	✓	✓
[38]	IEEE	5	✓	✓	✓	✓	✓
[39]	Springer	261		✓	✓	✓	✓
[14]	Elsevier	464	✓	✓	✓	✓	✓
[3]	IEEE	4	✓	✓	✓	✓	✓
[40]	IEEE	400	✓	✓	✓	✓	✓
[41]	Elsevier	12	✓	✓	✓	✓	✓
[42]	MDPI	9	✓	✓	✓	✓	✓
[43]	ACS	21	✓	✓	✓	✓	✓
[44]	IEEE	25	✓	✓	✓	✓	✓
[45]	Elsevier	21	✓	✓	✓	✓	✓
[46]	MDPI	6	✓	✓	✓	✓	✓
[47]	Elsevier	85	✓	✓	✓	✓	✓
[48]	MDPI	5	✓	✓	✓	✓	✓
[49]	MDPI	27	✓	✓	✓	✓	✓
[50]	MDPI	1	✓	✓	✓	✓	✓
[51]	ACM	5	✓	✓	✓	✓	✓
[52]	Elsevier	28	✓	✓	✓	✓	✓
[2]	Elsevier	2		✓	✓	✓	✓
[53]	Elsevier	3		✓	✓	✓	✓
[4]	Elsevier	20	✓	✓	✓	✓	✓
[54]	Springer	25	✓	✓	✓	✓	✓

Author	Publisher	Citation	RQ1	RQ2	RQ3	RQ4	RQ5
[18]	IEEE	28	✓	✓	✓	✓	✓
[55]	Elsevier	51	✓	✓	✓	✓	✓
[56]	Springer	33	✓	✓	✓	✓	✓
[57]	Taylor & Francis	152	✓	✓	✓	✓	✓
[10]	IEEE	9	✓	✓	✓	✓	✓
[58]	MDPI	54		✓	✓	✓	
[59]	Elsevier	77		✓	✓	✓	
[60]	Elsevier	5		✓	✓	✓	✓
[11]	IEEE	15		✓	✓	✓	✓
[61]	Elsevier	15	✓	✓	✓	✓	✓
[62]	Elsevier	34				✓	✓
[63]	Taylor & Francis	45	✓	✓	✓	✓	✓
[64]	Elsevier	11		✓	✓	✓	
[65]	Elsevier	0	✓	✓	✓	✓	✓
[66]	Elsevier	23		✓	✓	✓	✓
[67]	Elsevier	9		✓	✓	✓	✓
[68]	Elsevier	3		✓	✓	✓	✓
[69]	Elsevier	703		✓	✓	✓	
[70]	Elsevier	57	✓	✓		✓	✓
[1]	MDPI	59		✓	✓	✓	✓
[19]	Elsevier	100		✓	✓	✓	✓
[71]	ACM	68		✓	✓	✓	
[72]	Elsevier	175		✓	✓	✓	✓
[73]	Elsevier	94	✓	✓	✓	✓	✓
[74]	MDPI	13		✓	✓	✓	✓
[75]	MDPI	19			✓	✓	
[76]	IEEE	15	✓	✓	✓	✓	✓
[77]	IEEE	11		✓	✓	✓	✓
[21]	MDPI	3		✓	✓	✓	✓
[78]	Elsevier	65		✓	✓	✓	✓
[79]	MDPI	27	✓	✓	✓	✓	✓
[80]	MDPI	11	✓	✓	✓	✓	✓
[81]	Springer	11		✓	✓	✓	✓
[12]	IEEE	24		✓	✓	✓	✓
[82]	Elsevier	17	✓	✓	✓	✓	✓
[83]	JMIR	28	✓	✓	✓	✓	✓
[84]	Elsevier	1103		✓	✓	✓	
[85]	Springer	41		✓	✓	✓	✓

Author	Publisher	Citation	RQ1	RQ2	RQ3	RQ4	RQ5
[86]	MDPI	0	✓	✓	✓	✓	✓
[87]	MDPI	12		✓	✓	✓	✓
[88]	Springer	24		✓	✓	✓	✓
[89]	Springer	4	✓	✓	✓	✓	✓
[90]	Springer	0		✓	✓	✓	
[91]	MDPI	22	✓	✓	✓	✓	✓
[5]	Springer	6	✓	✓	✓	✓	✓
[92]	Taylor & Francis	6		✓	✓	✓	
[93]	Springer	41		✓	✓	✓	✓
[94]	Sage	0		✓	✓	✓	
[95]	Taylor & Francis	41	✓	✓	✓	✓	✓
[96]	Springer	8		✓	✓	✓	✓
[97]	POMS	16		✓	✓	✓	✓
[98]	Taylor & Francis	1	✓	✓	✓	✓	✓
[20]	Taylor & Francis	0	✓	✓	✓		✓
[99]	Springer	8		✓	✓	✓	✓
[100]	Emerald	47		✓	✓	✓	
[101]	Elsevier	42	✓	✓	✓	✓	✓
[102]	Elsevier	16	✓	✓	✓	✓	✓
[103]	Elsevier	36	✓	✓	✓	✓	✓
[104]	Elsevier	2		✓	✓	✓	✓
[105]	Elsevier	3	✓	✓	✓	✓	✓
[106]	Elsevier	20	✓	✓	✓	✓	✓
[107]	Elsevier	42	✓	✓	✓	✓	✓
[108]	Elsevier	11	✓	✓	✓	✓	✓
[109]	Elsevier	15	✓	✓	✓	✓	✓
[110]	Elsevier	169	✓	✓	✓	✓	✓
[111]	Elsevier	3		✓	✓	✓	✓
[112]	IEEE	43	✓	✓	✓	✓	✓
[113]	Elsevier	4		✓	✓	✓	✓
[114]	IEEE	967		✓	✓	✓	
[115]	Elsevier	112	✓	✓	✓	✓	✓
[116]	Elsevier	1	✓	✓	✓	✓	✓
[117]	Elsevier	0			✓	✓	✓
[118]	IEEE	7	✓	✓	✓	✓	✓
[119]	IEEE	14		✓	✓	✓	✓
[120]	IEEE	11		✓	✓	✓	✓
[121]	Elsevier	155	✓	✓	✓	✓	✓

Referensi

- [1] E. Gutierrez-Franco, C. Mejia-Argueta, and L. Rabelo, "Data-Driven Methodology to Support Long-Lasting Logistics and Decision Making for Urban Last-Mile Operations," *Sustainability*, vol. 13, no. 11, p. 6230, Jun. 2021, doi: 10.3390/su13116230.
- [2] R. B. Walton, F. W. Ciarallo, and L. E. Champagne, "A unified digital twin approach incorporating virtual, physical, and prescriptive analytical components to support adaptive real-time decision-making," *Comput. Ind. Eng.*, vol. 193, p. 110241, Jul. 2024, doi: 10.1016/j.cie.2024.110241.
- [3] Y. Zhao, J. Yang, W. Wang, H. Yang, and D. Niyato, "TranDRL: A Transformer-Driven Deep Reinforcement Learning Enabled Prescriptive Maintenance Framework," *IEEE Internet Things J.*, vol. 11, no. 21, pp. 35432–35444, Nov. 2024, doi: 10.1109/JIOT.2024.3436110.
- [4] N. Goby, T. Brandt, and D. Neumann, "Deep reinforcement learning with combinatorial actions spaces: An application to prescriptive maintenance," *Comput. Ind. Eng.*, vol. 179, p. 109165, May 2023, doi: 10.1016/j.cie.2023.109165.
- [5] R. Kumar, K. S. Sangwan, C. Herrmann, and R. Ghosh, "Development of a cyber physical production system framework for smart tool health management," *J. Intell. Manuf.*, vol. 35, no. 7, pp. 3037–3066, Oct. 2024, doi: 10.1007/s10845-023-02192-3.
- [6] A. Bousdekis, N. Papageorgiou, B. Magoutas, D. Apostolou, and G. Mentzas, "Sensor-driven Learning of Time-Dependent Parameters for Prescriptive Analytics," *IEEE Access*, pp. 1–1, 2020, doi: 10.1109/ACCESS.2020.2994933.
- [7] N. R. Haddaway, M. J. Page, C. C. Pritchard, and L. A. McGuinness, "PRISMA2020: An R package and Shiny app for producing PRISMA 2020-compliant flow diagrams, with interactivity for optimised digital transparency and Open Synthesis," *Campbell Syst. Rev.*, vol. 18, no. 2, pp. e1230–e1230, Mar. 2022, doi: 10.1002/cl2.1230.
- [8] B. Rihoux and B. Lobe, "The case for qualitative comparative analysis (QCA): Adding leverage for thick cross-case comparison," *Sage Handb. Case-Based Methods*, pp. 222–242, 2009.
- [9] R. K. Yin, *Applications of case study research*. Sage publications, 2011.
- [10] A. D. Cho, R. A. Carrasco, and G. A. Ruz, "Improving Prescriptive Maintenance by Incorporating Post-Prognostic Information Through Chance Constraints," *IEEE Access*, vol. 10, pp. 55924–55932, 2022, doi: 10.1109/ACCESS.2022.3177537.
- [11] E. M. Elfari, A. Rasheed, and O. San, "Artificial Intelligence-Driven Digital Twin of a Modern House Demonstrated in Virtual Reality," *IEEE Access*, vol. 11, pp. 35035–35058, 2023, doi: 10.1109/ACCESS.2023.3265191.
- [12] A. De Benedictis, F. Flammini, N. Mazzocca, A. Somma, and F. Vitale, "Digital Twins for Anomaly Detection in the Industrial Internet of Things: Conceptual Architecture and Proof-of-Concept," *IEEE Trans. Ind. Inform.*, vol. 19, no. 12, pp. 11553–11563, Dec. 2023, doi: 10.1109/TII.2023.3246983.
- [13] K. Leahy, C. Gallagher, P. O'Donovan, K. Bruton, and D. O'Sullivan, "A Robust Prescriptive Framework and Performance Metric for Diagnosing and Predicting Wind Turbine Faults Based on SCADA and Alarms Data with Case Study," *Energies*, vol. 11, no. 7, p. 1738, Jul. 2018, doi: 10.3390/en11071738.
- [14] A. Diez-Olivan, J. Del Ser, D. Galar, and B. Sierra, "Data fusion and machine learning for industrial prognosis: Trends and perspectives towards Industry 4.0," *Inf. Fusion*, vol. 50, pp. 92–111, Oct. 2019, doi: 10.1016/j.inffus.2018.10.005.
- [15] G. Gibey, E. Pahon, N. Zerhouni, and D. Hissel, "Diagnostic and prognostic for prescriptive maintenance and control of PEMFC systems in an industrial framework," *J. Power Sources*, vol. 613, p. 234864, Sep. 2024, doi: 10.1016/j.jpowsour.2024.234864.
- [16] K. Matyas, T. Nemeth, K. Kovacs, and R. Glawar, "A procedural approach for realizing prescriptive maintenance planning in manufacturing industries," *CIRP Ann.*, vol. 66, no. 1, pp. 461–464, 2017, doi: 10.1016/j.cirp.2017.04.007.

- [17] H. Fox, A. C. Pillai, D. Friedrich, M. Collu, T. Dawood, and L. Johanning, "A Review of Predictive and Prescriptive Offshore Wind Farm Operation and Maintenance," *Energies*, vol. 15, no. 2, p. 504, Jan. 2022, doi: 10.3390/en15020504.
- [18] F. Stadtmann *et al.*, "Digital Twins in Wind Energy: Emerging Technologies and Industry-Informed Future Directions," *IEEE Access*, vol. 11, pp. 110762–110795, 2023, doi: 10.1109/ACCESS.2023.3321320.
- [19] I. Ahmed, M. Ahmad, G. Jeon, and F. Piccialli, "A Framework for Pandemic Prediction Using Big Data Analytics," *Big Data Res.*, vol. 25, p. 100190, Jul. 2021, doi: 10.1016/j.bdr.2021.100190.
- [20] Ş. Karakaya, M. Yildirim, N. Gebraeel, and T. Xia, "A sensor-driven operations and maintenance planning approach for large-scale leased manufacturing systems," *Int. J. Prod. Res.*, vol. 62, no. 24, pp. 8701–8718, Dec. 2024, doi: 10.1080/00207543.2024.2347564.
- [21] B. Tektaş, H. H. Turan, N. Kasap, F. Çebi, and D. Delen, "A Fuzzy Prescriptive Analytics Approach to Power Generation Capacity Planning," *Energies*, vol. 15, no. 9, p. 3176, Apr. 2022, doi: 10.3390/en15093176.
- [22] B. Mazon-Olivo, D. Hernández-Rojas, J. Maza-Salinas, and A. Pan, "Rules engine and complex event processor in the context of internet of things for precision agriculture," *Comput. Electron. Agric.*, vol. 154, pp. 347–360, Nov. 2018, doi: 10.1016/j.compag.2018.09.013.
- [23] L. Pincirolì, P. Baraldi, M. Compare, and E. Zio, "Optimal operation and maintenance of energy storage systems in grid-connected microgrids by deep reinforcement learning," *Appl. Energy*, vol. 352, p. 121947, Dec. 2023, doi: 10.1016/j.apenergy.2023.121947.
- [24] C. A. K. Gordon and E. N. Pistikopoulos, "DATA-DRIVEN prescriptive maintenance toward FAULT-TOLERANT MULTIPARAMETRIC control," *AIChE J.*, vol. 68, no. 6, p. e17489, Jun. 2022, doi: 10.1002/aic.17489.
- [25] U. Elele, A. Nekahi, A. Arshad, I. Fofana, and K. McAulay, "Oil Quality Index Model Verification and Validation Using Total Acid Number and Interfacial Tension Experimental Data," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 31, no. 3, pp. 1340–1349, Jun. 2024, doi: 10.1109/TDEI.2024.3357665.
- [26] A. Kumar, R. B. Chinnam, and F. Tseng, "An HMM and polynomial regression based approach for remaining useful life and health state estimation of cutting tools," *Comput. Ind. Eng.*, vol. 128, pp. 1008–1014, Feb. 2019, doi: 10.1016/j.cie.2018.05.017.
- [27] O. Spyrou, C. Verdouw, and W. Hurst, "A digital twin reference architecture for pharmaceutical cannabis production," *Int. J. Comput. Integr. Manuf.*, vol. 37, no. 6, pp. 726–746, Jun. 2024, doi: 10.1080/0951192X.2023.2257635.
- [28] M. Koot, M. R. K. Mes, and M. E. Iacob, "A systematic literature review of supply chain decision making supported by the Internet of Things and Big Data Analytics," *Comput. Ind. Eng.*, vol. 154, p. 107076, Apr. 2021, doi: 10.1016/j.cie.2020.107076.
- [29] I. Esnaola-Gonzalez, J. Bermúdez, I. Fernandez, and A. Arnaiz, "Semantic prediction assistant approach applied to energy efficiency in Tertiary buildings," *Semantic Web*, vol. 9, no. 6, pp. 735–762, Sep. 2018, doi: 10.3233/SW-180296.
- [30] A. Dutta, I. A. Karimi, and S. Farooq, "PROAD (Process Advisor): A health monitoring framework for centrifugal pumps," *Comput. Chem. Eng.*, vol. 163, p. 107825, Jul. 2022, doi: 10.1016/j.compchemeng.2022.107825.
- [31] W. Adamczyk *et al.*, "Development and demonstration of advanced predictive and prescriptive algorithms to control industrial installation," *Energy*, vol. 313, p. 133648, Dec. 2024, doi: 10.1016/j.energy.2024.133648.
- [32] W. Wang, F. Di Maio, and E. Zio, "Adversarial Risk Analysis to Allocate Optimal Defense Resources for Protecting Cyber-Physical Systems from Cyber Attacks," *Risk Anal.*, vol. 39, no. 12, pp. 2766–2785, Dec. 2019, doi: 10.1111/risa.13382.
- [33] D. Kothona, I. P. Panapakidis, and G. C. Christoforidis, "Development of prescriptive maintenance methodology for maintenance cost minimization of photovoltaic systems," *Sol. Energy*, vol. 271, p. 112402, Mar. 2024, doi: 10.1016/j.solener.2024.112402.
- [34] D. Makarov, F. Vahdatikhaki, S. Miller, A. Jamshidi, and A. Dorée, "A framework for real-time compaction guidance system based on compaction priority mapping," *Autom. Constr.*, vol. 129, p. 103818, Sep. 2021, doi: 10.1016/j.autcon.2021.103818.

- [35] A. Arias, G. Feijoo, and M. T. Moreira, "How could Artificial Intelligence be used to increase the potential of biorefineries in the near future? A review," *Environ. Technol. Innov.*, vol. 32, p. 103277, Nov. 2023, doi: 10.1016/j.eti.2023.103277.
- [36] M. Bulut and E. Özcan, "Planning of prescriptive maintenance types for generator with fuzzy logic-based genetic algorithm in a hydroelectric power plant," *Expert Syst. Appl.*, vol. 240, p. 122480, Apr. 2024, doi: 10.1016/j.eswa.2023.122480.
- [37] M. Lombardi, M. Milano, and A. Bartolini, "Empirical decision model learning," *Artif. Intell.*, vol. 244, pp. 343–367, Mar. 2017, doi: 10.1016/j.artint.2016.01.005.
- [38] Y. Wang, A. Potter, M. Naim, A. Vafeas, A. Mavromatis, and D. Simeonidou, "5G Enabled Freeports: A Conceptual Framework," *IEEE Access*, vol. 10, pp. 91871–91887, 2022, doi: 10.1109/ACCESS.2022.3201889.
- [39] P. Kaur, R. Kumar, and M. Kumar, "A healthcare monitoring system using random forest and internet of things (IoT)," *Multimed. Tools Appl.*, vol. 78, no. 14, pp. 19905–19916, Jul. 2019, doi: 10.1007/s11042-019-7327-8.
- [40] M. G. Kibria, K. Nguyen, G. P. Villardi, O. Zhao, K. Ishizu, and F. Kojima, "Big Data Analytics, Machine Learning, and Artificial Intelligence in Next-Generation Wireless Networks," *IEEE Access*, vol. 6, pp. 32328–32338, 2018, doi: 10.1109/ACCESS.2018.2837692.
- [41] M. A. Mat Esa and M. Muhammad, "Adoption of prescriptive analytics for naval vessels risk-based maintenance: A conceptual framework," *Ocean Eng.*, vol. 278, p. 114409, Jun. 2023, doi: 10.1016/j.oceaneng.2023.114409.
- [42] D. E. Ighravwe, "Assessment of Sustainable Maintenance Strategy for Manufacturing Industry," *Sustainability*, vol. 14, no. 21, p. 13850, Oct. 2022, doi: 10.3390/su142113850.
- [43] C. A. K. Gordon, B. Burnak, M. Onel, and E. N. Pistikopoulos, "Data-Driven Prescriptive Maintenance: Failure Prediction Using Ensemble Support Vector Classification for Optimal Process and Maintenance Scheduling," *Ind. Eng. Chem. Res.*, vol. 59, no. 44, pp. 19607–19622, Nov. 2020, doi: 10.1021/acs.iecr.0c03241.
- [44] B. Liu, J. Lin, L. Zhang, and U. Kumar, "A Dynamic Prescriptive Maintenance Model Considering System Aging and Degradation," *IEEE Access*, vol. 7, pp. 94931–94943, 2019, doi: 10.1109/ACCESS.2019.2928587.
- [45] M. Subramaniyan, A. Skoogh, A. Sheikh Muhammad, J. Bokrantz, and E. Turanoğlu Bekar, "A prognostic algorithm to prescribe improvement measures on throughput bottlenecks," *J. Manuf. Syst.*, vol. 53, pp. 271–281, Oct. 2019, doi: 10.1016/j.jmsy.2019.07.004.
- [46] P. G. Martínez-Llop, J. D. D. Sanz Bobi, Á. Solano Jiménez, and J. Gutiérrez Sánchez, "Condition-Based Maintenance for Normal Behaviour Characterisation of Railway Car-Body Acceleration Applying Neural Networks," *Sustainability*, vol. 13, no. 21, p. 12265, Nov. 2021, doi: 10.3390/su132112265.
- [47] Z. Sedighi Maman, Y.-J. Chen, A. Baghdadi, S. Lombardo, L. A. Cavuoto, and F. M. Megahed, "A data analytic framework for physical fatigue management using wearable sensors," *Expert Syst. Appl.*, vol. 155, p. 113405, Oct. 2020, doi: 10.1016/j.eswa.2020.113405.
- [48] A. Papaioannou *et al.*, "LP-OPTIMA: A Framework for Prescriptive Maintenance and Optimization of IoT Resources for Low-Power Embedded Systems," *Sensors*, vol. 24, no. 7, p. 2125, Mar. 2024, doi: 10.3390/s24072125.
- [49] U. Elele, A. Nekahi, A. Arshad, and I. Fofana, "Towards Online Ageing Detection in Transformer Oil: A Review," *Sensors*, vol. 22, no. 20, p. 7923, Oct. 2022, doi: 10.3390/s22207923.
- [50] M. Rodríguez, A. Crespo, and V. González-Prida, "Enhancing Prescriptive Capabilities in Electrical Substations: A Systemic Impact Factor Approach for Failure Impact Analysis," *Energies*, vol. 17, no. 4, p. 770, Feb. 2024, doi: 10.3390/en17040770.
- [51] M. A. Hoffmann and R. Lasch, "Tackling Industrial Downtimes with Artificial Intelligence in Data-Driven Maintenance," *ACM Comput. Surv.*, vol. 56, no. 4, pp. 1–33, Apr. 2024, doi: 10.1145/3623378.
- [52] C.-H. Jeon, C.-S. Shim, Y.-H. Lee, and J. Schooling, "Prescriptive maintenance of prestressed concrete bridges considering digital twin and key performance indicator," *Eng. Struct.*, vol. 302, p. 117383, Mar. 2024, doi: 10.1016/j.engstruct.2023.117383.

- [53] L. Rabkin, I. Cohen, and G. Singer, "Resource allocation in ordinal classification problems: A prescriptive framework utilizing machine learning and mathematical programming," *Eng. Appl. Artif. Intell.*, vol. 132, p. 107914, Jun. 2024, doi: 10.1016/j.engappai.2024.107914.
- [54] N. Stein, J. Meller, and C. M. Flath, "Big data on the shop-floor: sensor-based decision-support for manual processes," *J. Bus. Econ.*, vol. 88, no. 5, pp. 593–616, Jul. 2018, doi: 10.1007/s11573-017-0890-4.
- [55] R. Meissner, A. Rahn, and K. Wicke, "Developing prescriptive maintenance strategies in the aviation industry based on a discrete-event simulation framework for post-prognostics decision making," *Reliab. Eng. Syst. Saf.*, vol. 214, p. 107812, Oct. 2021, doi: 10.1016/j.ress.2021.107812.
- [56] C.-Y. Lee and C.-F. Chien, "Pitfalls and protocols of data science in manufacturing practice," *J. Intell. Manuf.*, vol. 33, no. 5, pp. 1189–1207, Jun. 2022, doi: 10.1007/s10845-020-01711-w.
- [57] F. Ansari, R. Glawar, and T. Nemeth, "PriMa: a prescriptive maintenance model for cyber-physical production systems," *Int. J. Comput. Integr. Manuf.*, vol. 32, no. 4–5, pp. 482–503, May 2019, doi: 10.1080/0951192X.2019.1571236.
- [58] S. Zhang, K. Huang, and Y. Yuan, "Spare Parts Inventory Management: A Literature Review," *Sustainability*, vol. 13, no. 5, p. 2460, Feb. 2021, doi: 10.3390/su13052460.
- [59] N. Ariesen-Verschuur, C. Verdouw, and B. Tekinerdogan, "Digital Twins in greenhouse horticulture: A review," *Comput. Electron. Agric.*, vol. 199, p. 107183, Aug. 2022, doi: 10.1016/j.compag.2022.107183.
- [60] G. Roma, F. Di Maio, and E. Zio, "A condition-informed dynamic Bayesian network framework to support severe accident management in nuclear power plants," *Reliab. Eng. Syst. Saf.*, vol. 252, p. 110437, Dec. 2024, doi: 10.1016/j.ress.2024.110437.
- [61] F. Longo, A. Padovano, F. De Felice, A. Petrillo, and M. Elbasheer, "From 'prepare for the unknown' to 'train for what's coming': A digital twin-driven and cognitive training approach for the workforce of the future in smart factories," *J. Ind. Inf. Integr.*, vol. 32, p. 100437, Apr. 2023, doi: 10.1016/j.jii.2023.100437.
- [62] T. Sainati, G. Locatelli, and N. Smith, "Project financing in nuclear new build, why not? The legal and regulatory barriers," *Energy Policy*, vol. 129, pp. 111–119, Jun. 2019, doi: 10.1016/j.enpol.2019.01.068.
- [63] Y. Raptodimos and I. Lazakis, "Application of NARX neural network for predicting marine engine performance parameters," *Ships Offshore Struct.*, vol. 15, no. 4, pp. 443–452, Apr. 2020, doi: 10.1080/17445302.2019.1661619.
- [64] F. Ilizástigui Pérez, "Writing 'usable' Nuclear Power Plant (NPP) safety cases using bowtie methodology," *Process Saf. Environ. Prot.*, vol. 149, pp. 850–857, May 2021, doi: 10.1016/j.psep.2021.03.022.
- [65] J.-T. Sexton, M. Morin, R. Georges, F. Abasian, and J. Gaudreault, "Wood planer control: Predictive and prescriptive approaches via Automatic State Matching Gaussian processes," *Eng. Appl. Artif. Intell.*, vol. 132, p. 107843, Jun. 2024, doi: 10.1016/j.engappai.2024.107843.
- [66] S. Siddiqui, B. Zerhusen, M. Zehetmeier, and M. Effenberger, "Distribution of specific greenhouse gas emissions from combined heat-and-power production in agricultural biogas plants," *Biomass Bioenergy*, vol. 133, p. 105443, Feb. 2020, doi: 10.1016/j.biombioe.2019.105443.
- [67] P. Zvonek, O. Nusbaumer, and A. Torri, "Development of a Fully-Coupled, All States, All Hazards Level 2 PSA at Leibstadt Nuclear Power Plant," *Nucl. Eng. Technol.*, vol. 49, no. 2, pp. 426–433, Mar. 2017, doi: 10.1016/j.net.2017.01.016.
- [68] M. M. Li, P. Reinhard, C. Peters, S. Oeste-Reiss, and J. M. Leimeister, "A Value Co-Creation Perspective on Data Labeling in Hybrid Intelligence Systems: A Design Study," *Inf. Syst.*, vol. 120, p. 102311, Feb. 2024, doi: 10.1016/j.is.2023.102311.
- [69] S. S. Kamble, A. Gunasekaran, and S. A. Gawankar, "Achieving sustainable performance in a data-driven agriculture supply chain: A review for research and applications," *Int. J. Prod. Econ.*, vol. 219, pp. 179–194, Jan. 2020, doi: 10.1016/j.ijpe.2019.05.022.
- [70] V. N. Armstrong and C. Banks, "Integrated approach to vessel energy efficiency," *Ocean Eng.*, vol. 110, pp. 39–48, Dec. 2015, doi: 10.1016/j.oceaneng.2015.10.024.
- [71] H. Habibzadeh, C. Kaptan, T. Soyata, B. Kantarci, and A. Boukerche, "Smart City System Design: A Comprehensive Study of the Application and Data Planes," *ACM Comput. Surv.*, vol. 52, no. 2, pp. 1–38, Mar. 2020, doi: 10.1145/3309545.

- [72] D. Pessach, G. Singer, D. Avrahami, H. Chalutz Ben-Gal, E. Shmueli, and I. Ben-Gal, "Employees recruitment: A prescriptive analytics approach via machine learning and mathematical programming," *Decis. Support Syst.*, vol. 134, p. 113290, Jul. 2020, doi: 10.1016/j.dss.2020.113290.
- [73] D. Sjödin, V. Parida, and M. Kohtamäki, "Artificial intelligence enabling circular business model innovation in digital servitization: Conceptualizing dynamic capabilities, AI capacities, business models and effects," *Technol. Forecast. Soc. Change*, vol. 197, p. 122903, Dec. 2023, doi: 10.1016/j.techfore.2023.122903.
- [74] D. Brzezińska, P. Bryant, and A. S. Markowski, "An Alternative Evaluation and Indicating Methodology for Sustainable Fire Safety in the Process Industry," *Sustainability*, vol. 11, no. 17, p. 4693, Aug. 2019, doi: 10.3390/su11174693.
- [75] M. Baldin *et al.*, "Integrated Decision Support Systems (IDSS) for Dairy Farming: A Discussion on How to Improve Their Sustained Adoption," *Animals*, vol. 11, no. 7, p. 2025, Jul. 2021, doi: 10.3390/ani11072025.
- [76] Y. Liu *et al.*, "RadarVerses in Metaverses: A CPSI-Based Architecture for 6S Radar Systems in CPSS," *IEEE Trans. Syst. Man Cybern. Syst.*, vol. 53, no. 4, pp. 2128–2137, Apr. 2023, doi: 10.1109/TSMC.2022.3228590.
- [77] K. Lepenioti, A. Bousdekis, D. Apostolou, and G. Mentzas, "Human-Augmented Prescriptive Analytics With Interactive Multi-Objective Reinforcement Learning," *IEEE Access*, vol. 9, pp. 100677–100693, 2021, doi: 10.1109/ACCESS.2021.3096662.
- [78] C. Quinn, A. Z. Shabestari, T. Misic, S. Gilani, M. Litoiu, and J. J. McArthur, "Building automation system - BIM integration using a linked data structure," *Autom. Constr.*, vol. 118, p. 103257, Oct. 2020, doi: 10.1016/j.autcon.2020.103257.
- [79] S. Sharma, I. A. Karimi, S. Farooq, L. Samavedham, and R. Srinivasan, "Health Monitoring of Pressure Regulating Stations in Gas Distribution Networks Using Mathematical Models," *Energies*, vol. 15, no. 17, p. 6264, Aug. 2022, doi: 10.3390/en15176264.
- [80] R. A. D. F. Santiago *et al.*, "Data-Driven Models Applied to Predictive and Prescriptive Maintenance of Wind Turbine: A Systematic Review of Approaches Based on Failure Detection, Diagnosis, and Prognosis," *Energies*, vol. 17, no. 5, p. 1010, Feb. 2024, doi: 10.3390/en17051010.
- [81] G. Bonifazi, E. Corradini, D. Ursino, L. Virgili, E. Anceschi, and M. C. De Donato, "A machine learning based sentient multimedia framework to increase safety at work," *Multimed. Tools Appl.*, vol. 81, no. 1, pp. 141–169, Jan. 2022, doi: 10.1007/s11042-021-10984-z.
- [82] J. Tinoco, M. Parente, A. Gomes Correia, P. Cortez, and D. Toll, "Predictive and prescriptive analytics in transportation geotechnics: Three case studies," *Transp. Eng.*, vol. 5, p. 100074, Sep. 2021, doi: 10.1016/j.treng.2021.100074.
- [83] N. Musacchio *et al.*, "Artificial Intelligence and Big Data in Diabetes Care: A Position Statement of the Italian Association of Medical Diabetologists," *J. Med. Internet Res.*, vol. 22, no. 6, p. e16922, Jun. 2020, doi: 10.2196/16922.
- [84] G. Wang, A. Gunasekaran, E. W. T. Ngai, and T. Papadopoulos, "Big data analytics in logistics and supply chain management: Certain investigations for research and applications," *Int. J. Prod. Econ.*, vol. 176, pp. 98–110, Jun. 2016, doi: 10.1016/j.ijpe.2016.03.014.
- [85] R. Riedl, "Is trust in artificial intelligence systems related to user personality? Review of empirical evidence and future research directions," *Electron. Mark.*, vol. 32, no. 4, pp. 2021–2051, Dec. 2022, doi: 10.1007/s12525-022-00594-4.
- [86] J. N. D. Carvalho, F. R. D. Silva, and E. G. S. Nascimento, "Challenges of the Biopharmaceutical Industry in the Application of Prescriptive Maintenance in the Industry 4.0 Context: A Comprehensive Literature Review," *Sensors*, vol. 24, no. 22, p. 7163, Nov. 2024, doi: 10.3390/s24227163.
- [87] J. Mateo-Fornés, A. Pagès-Bernaus, L. M. Plà-Aragonés, J. P. Castells-Gasia, and D. Babot-Gaspa, "An Internet of Things Platform Based on Microservices and Cloud Paradigms for Livestock," *Sensors*, vol. 21, no. 17, p. 5949, Sep. 2021, doi: 10.3390/s21175949.
- [88] T. Susnjak, "Beyond Predictive Learning Analytics Modelling and onto Explainable Artificial Intelligence with Prescriptive Analytics and ChatGPT," *Int. J. Artif. Intell. Educ.*, vol. 34, no. 2, pp. 452–482, Jun. 2024, doi: 10.1007/s40593-023-00336-3.

- [89] A. Consilvio, G. Vignola, P. López Arévalo, F. Gallo, M. Borinato, and C. Crovetto, “A data-driven prioritisation framework to mitigate maintenance impact on passengers during metro line operation,” *Eur. Transp. Res. Rev.*, vol. 16, no. 1, p. 6, Jan. 2024, doi: 10.1186/s12544-023-00631-z.
- [90] M. Brennecke, G. Fridgen, J. Jöhnk, S. Radszuwill, and J. Sedlmeir, “When Your Thing Won’t Behave: Security Governance in the Internet of Things,” *Inf. Syst. Front.*, Aug. 2024, doi: 10.1007/s10796-024-10511-z.
- [91] Y. Liu *et al.*, “Parallel Radars: From Digital Twins to Digital Intelligence for Smart Radar Systems,” *Sensors*, vol. 22, no. 24, p. 9930, Dec. 2022, doi: 10.3390/s22249930.
- [92] B. T. Denton, “Frontiers of medical decision-making in the modern age of data analytics,” *IISE Trans.*, vol. 55, no. 1, pp. 94–105, Jan. 2023, doi: 10.1080/24725854.2022.2092918.
- [93] A. A. Nadiri, M. Gharekhani, and R. Khatibi, “Mapping Aquifer Vulnerability Indices Using Artificial Intelligence-running Multiple Frameworks (AIMF) with Supervised and Unsupervised Learning,” *Water Resour. Manag.*, vol. 32, no. 9, pp. 3023–3040, Jul. 2018, doi: 10.1007/s11269-018-1971-z.
- [94] J.-N. Kim, M. M. Chiu, H. Lee, Y. W. Oh, H. Gil De Zúñiga, and C. H. Park, “Mapping Media Research Paradigms: *Journalism & Mass Communication Quarterly*’s Century of Scientific Evolution,” *Journal. Mass Commun. Q.*, vol. 100, no. 4, pp. 736–772, Dec. 2023, doi: 10.1177/10776990231213376.
- [95] S. Lavy, J. A. Garcia, P. Scinto, and M. K. Dixit, “Key performance indicators for facility performance assessment: simulation of core indicators,” *Constr. Manag. Econ.*, vol. 32, no. 12, pp. 1183–1204, Dec. 2014, doi: 10.1080/01446193.2014.970208.
- [96] E. Yildiz, C. Møller, and A. Bilberg, “Conceptual foundations and extension of digital twin-based virtual factory to virtual enterprise,” *Int. J. Adv. Manuf. Technol.*, vol. 121, no. 3–4, pp. 2317–2333, Jul. 2022, doi: 10.1007/s00170-022-09462-z.
- [97] S. Gupta, H. Rikhtehgar Berenji, M. Shukla, and N. N. Murthy, “Opportunities in farming research from an operations management perspective,” *Prod. Oper. Manag.*, vol. 32, no. 6, pp. 1577–1596, Jun. 2023, doi: 10.1111/poms.13967.
- [98] E. Pearlstein, “Teaching Sustainable Collection Care,” *J. Am. Inst. Conserv.*, vol. 56, no. 2, pp. 113–125, Apr. 2017, doi: 10.1080/01971360.2016.1217726.
- [99] A. Mammadov, G. Kazar, K. Koc, and O. B. Tokdemir, “Predicting Accident Outcomes in Cross-Border Pipeline Construction Projects Using Machine Learning Algorithms,” *Arab. J. Sci. Eng.*, vol. 48, no. 10, pp. 13771–13789, Oct. 2023, doi: 10.1007/s13369-023-07964-w.
- [100] L. Ardito, R. Cerchione, E. Mazzola, and E. Raguseo, “Industry 4.0 transition: a systematic literature review combining the absorptive capacity theory and the data–information–knowledge hierarchy,” *J. Knowl. Manag.*, vol. 26, no. 9, pp. 2222–2254, Sep. 2022, doi: 10.1108/JKM-04-2021-0325.
- [101] Z. Y. Wu *et al.*, “High Fidelity Digital Twin-Based Anomaly Detection and Localization for Smart Water Grid Operation Management,” *Sustain. Cities Soc.*, vol. 91, p. 104446, Apr. 2023, doi: 10.1016/j.scs.2023.104446.
- [102] X. Wang *et al.*, “The survey on multi-source data fusion in cyber-physical-social systems: Foundational infrastructure for industrial metaverses and industries 5.0,” *Inf. Fusion*, vol. 107, p. 102321, Jul. 2024, doi: 10.1016/j.inffus.2024.102321.
- [103] X. Tian, R. Yan, Y. Liu, and S. Wang, “A smart predict-then-optimize method for targeted and cost-effective maritime transportation,” *Transp. Res. Part B Methodol.*, vol. 172, pp. 32–52, Jun. 2023, doi: 10.1016/j.trb.2023.03.009.
- [104] C. Gnekpe, D. Tchunte, S. Nyawa, and P. K. Dey, “Energy Performance of Building Refurbishments: Predictive and Prescriptive AI-based Machine Learning Approaches,” *J. Bus. Res.*, vol. 183, p. 114821, Oct. 2024, doi: 10.1016/j.jbusres.2024.114821.
- [105] M. L. Chaves Franz, N. F. Ayala, and A. M. Larranaga, “Industry 4.0 for passenger railway companies: A maturity model proposal for technology management,” *J. Rail Transp. Plan. Manag.*, vol. 32, p. 100480, Dec. 2024, doi: 10.1016/j.jrtpm.2024.100480.
- [106] M. Marzouk and N. Seleem, “Assessment of existing buildings performance using system dynamics technique,” *Appl. Energy*, vol. 211, pp. 1308–1323, Feb. 2018, doi: 10.1016/j.apenergy.2017.10.111.

- [107] U. Leturiondo, O. Salgado, L. Ciani, D. Galar, and M. Catelani, "Architecture for hybrid modelling and its application to diagnosis and prognosis with missing data," *Measurement*, vol. 108, pp. 152–162, Oct. 2017, doi: 10.1016/j.measurement.2017.02.003.
- [108] A. Al Hanbali, H. H. Saleh, O. G. Alsawafy, A. M. Attia, A. M. Ghaithan, and A. Mohammed, "Spare parts supply with incoming quality control and inspection errors in condition based maintenance," *Comput. Ind. Eng.*, vol. 172, p. 108534, Oct. 2022, doi: 10.1016/j.cie.2022.108534.
- [109] C. Nakousi, R. Pascual, A. Anani, F. Kristjanpoller, and P. Lillo, "An asset-management oriented methodology for mine haul-fleet usage scheduling," *Reliab. Eng. Syst. Saf.*, vol. 180, pp. 336–344, Dec. 2018, doi: 10.1016/j.ress.2018.07.034.
- [110] J. Lee, B. Bagheri, and C. Jin, "Introduction to cyber manufacturing," *Manuf. Lett.*, vol. 8, pp. 11–15, Apr. 2016, doi: 10.1016/j.mfglet.2016.05.002.
- [111] P. M. Notz, P. K. Wolf, and R. Pibernik, "Prescriptive analytics for a multi-shift staffing problem," *Eur. J. Oper. Res.*, vol. 305, no. 2, pp. 887–901, Mar. 2023, doi: 10.1016/j.ejor.2022.06.011.
- [112] T. Panayiotou, M. Michalopoulou, and G. Ellinas, "Survey on Machine Learning for Traffic-Driven Service Provisioning in Optical Networks," *IEEE Commun. Surv. Tutor.*, vol. 25, no. 2, pp. 1412–1443, 2023, doi: 10.1109/COMST.2023.3247842.
- [113] W. Hoyos, J. Aguilar, M. Raciny, and M. Toro, "Case studies of clinical decision-making through prescriptive models based on machine learning," *Comput. Methods Programs Biomed.*, vol. 242, p. 107829, Dec. 2023, doi: 10.1016/j.cmpb.2023.107829.
- [114] Y. Wang, Q. Chen, T. Hong, and C. Kang, "Review of Smart Meter Data Analytics: Applications, Methodologies, and Challenges," *IEEE Trans. Smart Grid*, vol. 10, no. 3, pp. 3125–3148, May 2019, doi: 10.1109/TSG.2018.2818167.
- [115] S. Srinivas and A. R. Ravindran, "Optimizing outpatient appointment system using machine learning algorithms and scheduling rules: A prescriptive analytics framework," *Expert Syst. Appl.*, vol. 102, pp. 245–261, Jul. 2018, doi: 10.1016/j.eswa.2018.02.022.
- [116] A. Papaioannou *et al.*, "A novel AI-powered method for robust identification of operational phases in refrigerators," *Sustain. Energy Grids Netw.*, vol. 39, p. 101405, Sep. 2024, doi: 10.1016/j.segan.2024.101405.
- [117] S. Cromie and F. Bott, "Just culture's 'line in the sand' is a shifting one; an empirical investigation of culpability determination," *Saf. Sci.*, vol. 86, pp. 258–272, Jul. 2016, doi: 10.1016/j.ssci.2016.03.012.
- [118] S. Singh, R. Batheri, and J. Dias, "Predictive Analytics: How to Improve Availability of Manufacturing Equipment in Automotive Firms," *IEEE Eng. Manag. Rev.*, vol. 51, no. 4, pp. 157–168, Dec. 2023, doi: 10.1109/EMR.2023.3288669.
- [119] Y. Liu *et al.*, "MetaSensing in Metaverses: See There, Be There, and Know There," *IEEE Intell. Syst.*, vol. 37, no. 6, pp. 7–12, Nov. 2022, doi: 10.1109/MIS.2022.3221844.
- [120] J. Wang, X. Wang, Y. Tian, Y. Wang, J. Niu, and O. Kwan, "Parallel Training: An ACP-Based Training Framework for Iterative Learning in Uncertain Driving Spaces," *IEEE Trans. Intell. Veh.*, vol. 8, no. 4, pp. 2832–2841, Apr. 2023, doi: 10.1109/TIV.2023.3249287.
- [121] Z. Zhu, N. Anwer, Q. Huang, and L. Mathieu, "Machine learning in tolerancing for additive manufacturing," *CIRP Ann.*, vol. 67, no. 1, pp. 157–160, 2018, doi: 10.1016/j.cirp.2018.04.119.

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.