

From Predictive to Prescriptive Maintenance in Power Generation: An Integrated Five-Layer Framework Validated through Systematic Comparative Analysis

Oleh:

Ahmad Fauzan

Rita Ambarwati Sukmono

Progam Studi

Universitas Muhammadiyah Sidoarjo

17 Juli, 2025

Pendahuluan

Selama beberapa dekade terakhir, pemeliharaan di industri telah mulai bergeser dari pemeliharaan reactive ke arah pemeliharaan preskriptif (RxM), pendekatan proaktif berbasis data yang memprediksi kegagalan dan merekomendasikan tindakan optimal. Dalam pembangkit listrik, RxM meningkatkan efisiensi dan keandalan melalui teknologi seperti IoT, kembaran digital, dan pembelajaran mesin. Namun, banyak model RxM masih terfragmentasi, seperti tidak memiliki mekanisme execution dan feedback, serta juga menghadapi masalah integrasi dengan sistem yang sudah ada. Studi ini berupaya mengembangkan five-layer framework RxM dimana terdapat pengumpulan data (Data Collection), analitik (Data Analytic), pengambilan Keputusan (Decision Making), eksekusi (Execution), dan umpan balik (Feedback), berdasarkan Systematic Literature Review (SLR) dan Systematic Comparative Analysis (SCA). Yang mana bertujuan sebagai guide implementasi RxM yang skalabel, khususnya dalam pembangkit listrik.

Pertanyaan Penelitian

1. RQ1 – Apa yang membedakan pemeliharaan preskriptif dari pendekatan prediktif dalam hal konsep dan nilai?
2. RQ2 – Teknologi apa saja yang mendukung penerapan pemeliharaan preskriptif dalam pembangkit listrik?
3. RQ3 – Komponen arsitektur apa yang mendefinisikan kerangka kerja RxM yang modular dan dapat digeneralisasi ?
4. RQ4 – Apa saja tantangan utama dalam penerapan RxM ?
5. RQ5 – Bagaimana kerangka kerja yang ada telah divalidasi, dan bagaimana validasi dapat meningkatkan kredibilitas model yang diusulkan?

Metode

Penelitian ini mengadopsi pendekatan eksploratif kualitatif berdasarkan Systematic Literature Review (SLR) dengan protokol PRISMA 2020.

1. Strategi Pencarian Literatur

Tabel 1. Kriteria Inklusi dan Eksklusi

Kriteria Inklusi	Kriteria Pengecualian
Diterbitkan dalam bahasa Inggris	Artikel yang berfokus secara eksklusif pada pemeliharaan prediktif
Terindeks di jurnal Scopus Q1 (diterbitkan antara tahun 2014 dan 2024)	Studi yang tidak membahas konsep pemeliharaan preskriptif, kerangka kerja, atau implementasi
Menangani setidaknya satu komponen RxM (misalnya, analisis data, pengambilan keputusan, umpan balik)	
Relevan dengan aplikasi pemeliharaan preskriptif, termasuk namun tidak terbatas pada sektor industri dan energi	

Metode

2. Teknik Ekstraksi dan Klasifikasi Data

Setiap artikel dalam tinjauan ini dianalisis secara menyeluruh untuk mengumpulkan informasi kunci, misalnya informasi dasar seperti penulis, tahun, negara, dan industri yang diteliti. Fokus utama adalah pada definisi prescriptive maintenance, struktur framework (termasuk akuisisi data, analitik, pengambilan keputusan, eksekusi, dan umpan balik), tantangan implementasi, dan metode evaluasi efektivitas. Data diklasifikasikan ke dalam tematik konseptual, teknologi, struktural, dan evaluatif menggunakan matriks Excel. Sintesis tematik ini membantu mengidentifikasi pola-pola umum dan menghubungkannya dengan lima pertanyaan penelitian utama dalam studi ini.

3. Proses Pengembangan Framework yang Diusulkan


Kerangka kerja RxM dikembangkan melalui proses terstruktur dan multi-tahap menggunakan Systematic Literature Review berdasarkan PRISMA2020. Studi-studi yang relevan diklasifikasikan dan disintesis secara tematis untuk merancang kerangka kerja lima lapis: pengumpulan data, analitik, pengambilan keputusan, eksekusi, dan umpan balik. Kerangka kerja ini divalidasi dengan membandingkannya dengan tujuh benchmark study.

Metode

4. Validasi Framework menggunakan Systematic Comparative Analysis (SCA)

Kerangka kerja ini divalidasi melalui analisis komparatif sistematis terhadap tujuh benchmark study terhadap lima lapisan fungsional: pengumpulan data, analitik, pengambilan keputusan, eksekusi, dan umpan balik. Hasil menunjukkan bahwa model yang diusulkan menawarkan struktur yang lebih lengkap, terutama dalam hal eksekusi dan umpan balik. Namun, pengujian empiris masih diperlukan untuk validasi praktis.

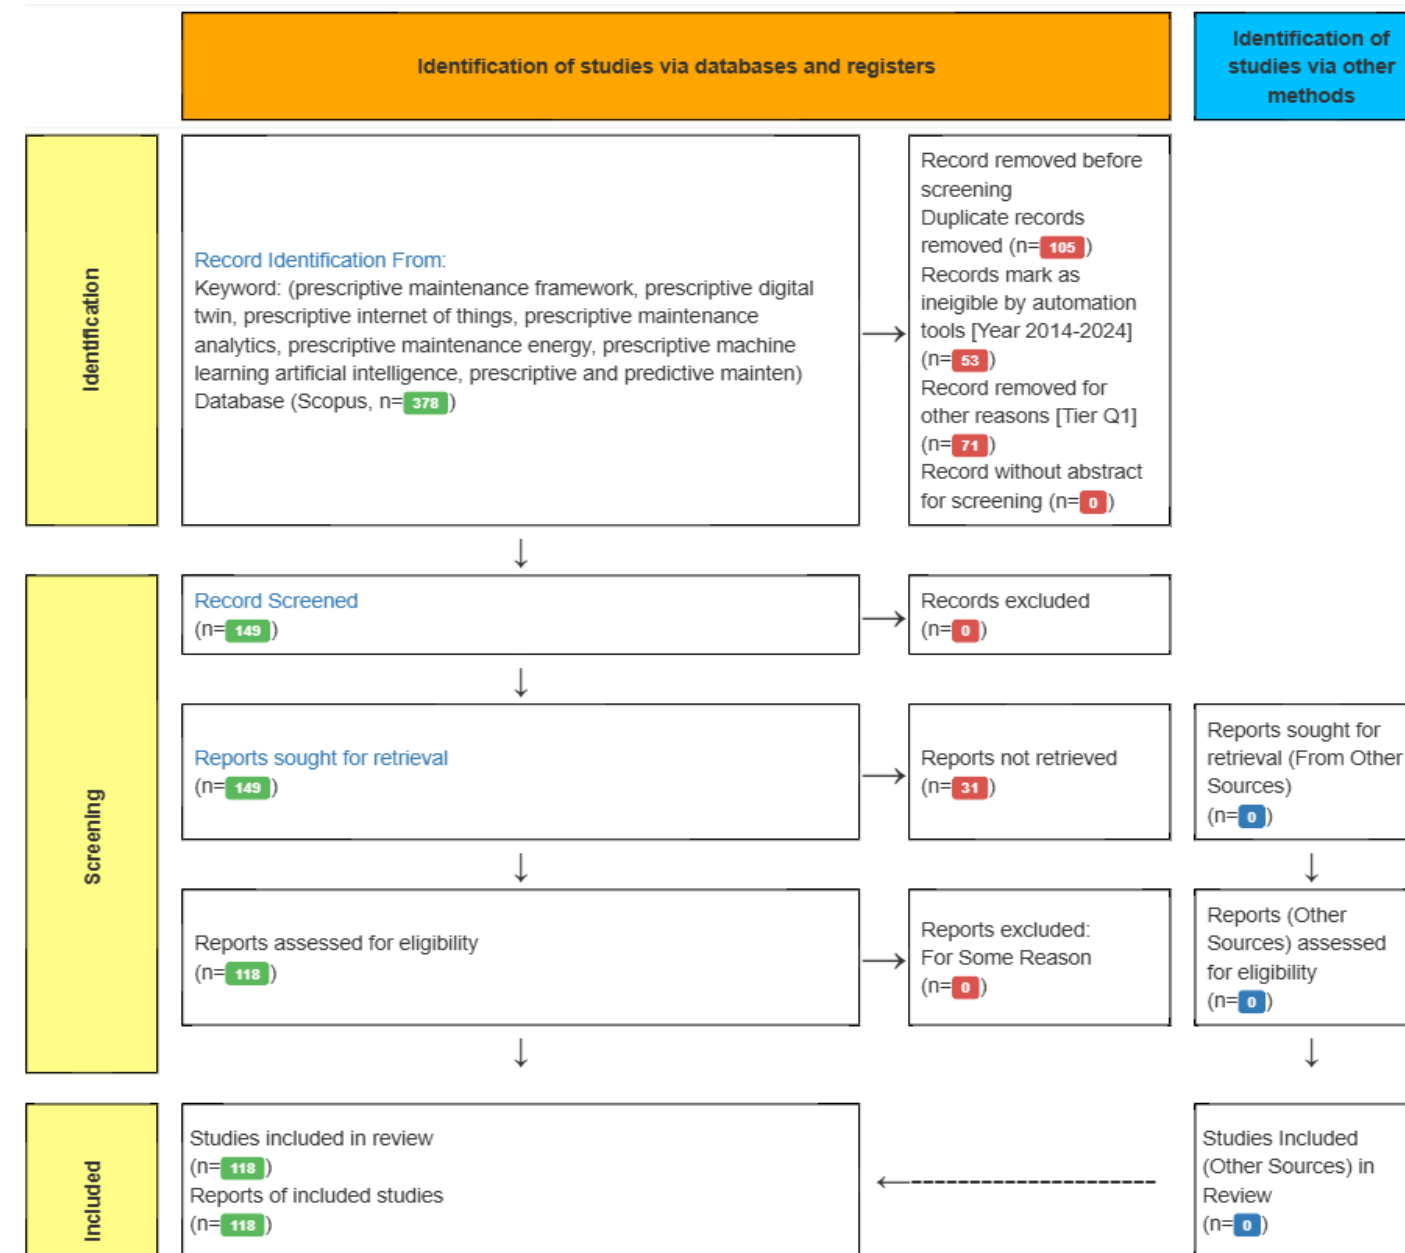
Metode



Gambar 1. Diagram Alir untuk Mengembangkan Kerangka Kerja RxM yang Diusulkan

Hasil


1. Tinjauan Literatur Terpilih



Gambar 2. Diagram alir PRISMA dari proses seleksi

Hasil

2. Tren Publikasi



Gambar 3. Distribusi publikasi berdasarkan tahun (2014–2024).

Hasil

Analisis awan kata yang dihasilkan dari artikel-artikel terpilih mengungkapkan serangkaian istilah yang kaya dan beragam yang mencerminkan fondasi teknologi dan prioritas strategis pemeliharaan preskriptif.




Gambar 3. Word Cloud Visualization

Hasil

4. Distribusi berdasarkan Domain Industri

Literatur yang diulas mencakup berbagai sektor, dengan porsi studi terbesar berfokus pada manufaktur, yaitu 38 artikel, diikuti oleh sistem energi dengan 25 artikel. Hal ini menunjukkan fokus yang kuat pada industri yang sangat bergantung pada aset fisik. Bidang lain yang terwakili meliputi transportasi dengan 15 studi, 17 artikel dari domain campuran atau tidak spesifik, dan beberapa bidang yang sedang berkembang seperti jaringan mikro dengan 10 publikasi, layanan kesehatan dengan 8 publikasi, dan kedingantaraan dengan 6 publikasi.




Gambar 4. Distribusi publikasi berdasarkan domain industri (2014–2024).

Hasil

5. Distribusi berdasarkan Outlet Jurnal

Artikel yang ditinjau berasal dari berbagai jurnal Scopus Q1, menunjukkan cakupan multidisipliner prescriptive maintenance. Dua puluh jurnal paling aktif termasuk IEEE Access, Sustainability, dan Energies, masing-masing menyumbang 6–7 artikel (lihat Gambar 6). Jurnal lain seperti Sensors, Expert Systems with Applications, dan Reliability Engineering and System Safety juga sering dikutip. Ini menunjukkan bahwa topik ini dibahas luas, tidak hanya di jurnal pemeliharaan, tetapi juga di bidang rekayasa, AI, dan pengambilan keputusan, menegaskan pentingnya prescriptive maintenance dalam lingkungan operasional modern.



Gambar 6. Klasifikasi 20 jurnal teratas publikasi RxM (2014–2024).

Hasil

6. Hasil Ekstraksi Artikel

Data yang diekstraksi mencakup berbagai aspek, termasuk definisi konseptual, teknologi yang memungkinkan, struktur kerangka kerja, masalah implementasi praktis, dan metode validasi.

Tabel 2. Ringkasan Karakteristik Artikel dan Cakupan RQ

Kriteria	Ringkasan
Jumlah Artikel	118
Tahun Publikasi	Tahun 2017-2024
Rata-rata Sitasi	61 kutipan
Penerbit Utama	Elsevier, IEEE, MDPI, Springer, Taylor & Francis
Cakupan RQ1	70 artikel
Cakupan RQ2	115 artikel
Cakupan RQ3	116 artikel
Cakupan RQ4	117 artikel
Cakupan RQ5	105 artikel

Framework usulan

Sebelum validasi komparatif, dipilih tujuh studi acuan berdasarkan 118 artikel melalui tiga kriteria: implementasi nyata atau simulasi, adanya lapisan fungsional prescriptive maintenance, dan relevansi namun tidak terbatas pada pembangkit listrik. Studi terpilih berasal dari sektor seperti sistem siber-fisik, dirgantara, dan otomasi industri. Analisis dilakukan berdasarkan lima lapisan inti: pengumpulan data, analitik, pengambilan keputusan, eksekusi, dan umpan balik

Layer	Proposed Framework	(Gutierrez-Franco et al., 2021)	(R. Kumar et al., 2024)	(Zhao et al., 2024)	(Goby et al., 2023)	(Walton et al., 2024)	(Leahy et al., 2018)	(Bousdekis et al., 2020)
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.

Framework usulan

Layer	Inputs/Substeps	Techniques / Components	Output/Process
 Data Collection 1	IoT Sensors, SCADA Systems, MES Platforms, Historical Maintenance Logs 1.1	None 1.2	Integrate real-time and historical data 1.3
 Data Processing and Analytics 2	Data Cleansing and Normalization, Feature Extraction and Anomaly Detection 2.1	Machine Learning Model: SVM, RF, ANN, DRL, Uncertainty Quantification 2.2	Prescriptive Insight: Failure Forecasting, Remaining Useful Life (RUL) 2.3
 Decision-Making 3	Prescriptive Insight 3.1	Optimization (MINLP, GA), Multi-Criteria Decision Making (AHP, TOPSIS), Rule-Based Expert Systems, DRL-Based Policy Learning 3.2	Prescriptive Maintenance Recommendations 3.3
 Execution 4	Prescriptive Maintenance Recommendations 4.1	Digital Twin Simulation Validation, Mobile & Automated Workflow Deployment, Action Implementation via Maintenance Systems 4.2	Executed Maintenance Actions 4.3
 Feedback 5	Executed Maintenance Action 5.1	Real-Time Performance Monitoring, Model Recalibration and Retraining 5.2	Continuous Learning Integration To Machine Learning Model (2.2) 5.3

Gambar 7. Framework Pemeliharaan Preskriptif (RxM) yang Diusulkan

Pembahasan

1. Konsep Inti RxM (RQ1)

Pemeliharaan Preskriptif (RxM) adalah pendekatan pemeliharaan yang lebih canggih dari pada Pemeliharaan Prediktif (PdM). PdM hanya memprediksi kapan kegagalan akan terjadi, sementara RxM melangkah lebih jauh, memberikan rekomendasi spesifik tentang tindakan yang harus diambil, kapan, dan dalam kondisi apa. RxM menggabungkan analitik data waktu nyata, model optimasi, dan umpan balik adaptif untuk mendukung pengambilan keputusan yang proaktif dan strategis. Studi sebelumnya telah menunjukkan bahwa RxM meningkatkan keandalan aset, mengurangi waktu henti yang tidak direncanakan, dan menyelaraskan pemeliharaan dengan tujuan produksi.

2. Teknologi yang Mendukung Implementasi RxM (RQ2)

Teknologi kunci yang mendukung RxM meliputi: Internet of Things (IoT) untuk pemantauan kondisi aset secara real-time, Machine Learning (ML) dan Deep Reinforcement Learning (DRL) untuk deteksi anomali dan penentuan kebijakan pemeliharaan yang optimal, serta Digital Twin untuk simulasi dan validasi virtual sebelum tindakan di dunia nyata. Kombinasi teknologi ini mendukung sistem pemeliharaan yang cerdas dan adaptif.

Pembahasan

3. Komponen Struktural Kerangka RxM Umum (RQ3)

RxM yang umum terdiri dari lima lapisan fungsional: Data Collection (pengumpulan data dari sensor dan sistem SCADA), Data Analytics (pemrosesan dan analisis data dengan ML), Decision Making (menentukan tindakan melalui pengoptimalan), Execution (eksekusi melalui CMMS dan sistem eksekusi lainnya), dan Feedback (umpan balik untuk pembelajaran sistem. Struktur ini memungkinkan fleksibilitas dan modularitas, sehingga dapat diadaptasi ke berbagai konteks industri pembangkit listrik).

4. Tantangan dan Peluang Implementasi (RQ4)

Tantangan utama dalam implementasi RxM meliputi: Mengintegrasikan data dari sistem lama, Keterbatasan infrastruktur di fasilitas lama, Kurangnya kepercayaan pada sistem AI, Kesenjangan keterampilan dan koordinasi antar tim.

Namun, peluang juga muncul melalui: Arsitektur modular untuk penerapan bertahap, AI yang dapat dijelaskan (XAI) untuk meningkatkan transparansi, Sensor berbiaya rendah, dan edge-computing yang semakin terjangkau.

Pembahasan

5. Validasi Praktis dan Kredibilitas Kerangka RxM (RQ5)

Sebagian besar validasi dalam literatur masih didasarkan pada simulasi dan prototipe. Studi ini menggunakan Analisis Komparatif Sistematis (SCA) untuk mengevaluasi keselarasan struktural dengan tujuh model RxM yang ada . Hasilnya menunjukkan bahwa banyak model tidak mengintegrasikan eksekusi dan umpan balik secara formal. Kerangka kerja yang diusulkan dalam studi ini mengatasi kesenjangan ini dan menawarkan fondasi yang lebih komprehensif dan adaptif. Namun, validasi lapangan masih diperlukan untuk menguji kelayakan dalam lingkungan operasional dunia nyata.

Kesimpulan dan Penelitian Selanjutnya

Studi ini mengeksplorasi pengembangan dan penerapan Prescriptive Maintenance (RxM) di sektor pembangkit listrik melalui tinjauan sistematis terhadap 118 sumber akademis yang diterbitkan antara tahun 2014 dan 2024. Penelitian ini merumuskan pemahaman komprehensif tentang RxM dengan membahas fondasi konseptualnya, teknologi pendukung, arsitektur sistem, tantangan implementasi, dan pendekatan validasi. Ini mengusulkan kerangka kerja lima lapis modular yang mencakup pengumpulan data, analitik, pengambilan keputusan, eksekusi, dan umpan balik, yang dirancang untuk menawarkan solusi yang fleksibel dan terukur untuk lingkungan operasional yang kompleks di pembangkit listrik. Tidak seperti pemeliharaan prediktif, RxM tidak hanya memperkirakan kegagalan tetapi juga memberikan rekomendasi spesifik yang sadar konteks dengan memanfaatkan teknologi seperti IoT, pembelajaran mesin, kembaran digital, dan pembelajaran penguatan mendalam. Sementara kerangka kerja tersebut selaras dengan model yang ada, ia menyempurnakannya dengan mengintegrasikan elemen yang sering diabaikan seperti mekanisme eksekusi dan Feedback. Terlepas dari potensinya, adopsi RxM di dunia nyata menghadapi hambatan termasuk interoperabilitas sistem, kepercayaan yang terbatas pada saran yang dihasilkan AI, dan kesiapan organisasi. Oleh karena itu, studi ini menekankan pentingnya implementasi yang transparan dan bertahap serta menyoroti perlunya validasi lapangan untuk mengukur kinerja dalam kondisi operasional. Studi ini juga menyerukan penelitian di masa mendatang tentang aspek-aspek yang berpusat pada manusia, seperti pelatihan tenaga kerja dan pertimbangan etika, yang sejalan dengan tujuan Industri 5.0.

Reference

Adamczyk, W., Myöhänen, K., Klajny, M., Kettunen, A., Klimanek, A., Ryfa, A., Białecki, R., Śladek, S., Zdeb, J., Budnik, M., Peczkis, G., Przybyła, G., Gładysz, P., Pawlak, S., Zhou, M., Jachymek, P., & Andrzejczyk, M. (2024). Development and demonstration of advanced predictive and prescriptive algorithms to control industrial installation. *Energy*, 313, 133648. <https://doi.org/10.1016/j.energy.2024.133648>

Ahmed, I., Ahmad, M., Jeon, G., & Piccialli, F. (2021). A Framework for Pandemic Prediction Using Big Data Analytics. *Big Data Research*, 25, 100190. <https://doi.org/10.1016/j.bdr.2021.100190>

Al Hanbali, A., Saleh, H. H., Alsawafy, O. G., Attia, A. M., Ghaithan, A. M., & Mohammed, A. (2022). Spare parts supply with incoming quality control and inspection errors in condition based maintenance. *Computers & Industrial Engineering*, 172, 108534. <https://doi.org/10.1016/j.cie.2022.108534>

Ansari, F., Glawar, R., & Nemeth, T. (2019). PriMa: A prescriptive maintenance model for cyber-physical production systems. *International Journal of Computer Integrated Manufacturing*, 32(4–5), 482–503. <https://doi.org/10.1080/0951192X.2019.1571236>

Ardito, L., Cerchione, R., Mazzola, E., & Raguseo, E. (2022). Industry 4.0 transition: A systematic literature review combining the absorptive capacity theory and the data–information–knowledge hierarchy. *Journal of Knowledge Management*, 26(9), 2222–2254. <https://doi.org/10.1108/JKM-04-2021-0325>

Arias, A., Feijoo, G., & Moreira, M. T. (2023). How could Artificial Intelligence be used to increase the potential of biorefineries in the near future? A review. *Environmental Technology & Innovation*, 32, 103277. <https://doi.org/10.1016/j.eti.2023.103277>

Ariesen-Verschuur, N., Verdouw, C., & Tekinerdogan, B. (2022). Digital Twins in greenhouse horticulture: A review. *Computers and Electronics in Agriculture*, 199, 107183. <https://doi.org/10.1016/j.compag.2022.107183>

Armstrong, V. N., & Banks, C. (2015). Integrated approach to vessel energy efficiency. *Ocean Engineering*, 110, 39–48. <https://doi.org/10.1016/j.oceaneng.2015.10.024>

Baldin, M., Breunig, T., Cue, R., De Vries, A., Doornink, M., Drevenak, J., Fourdraine, R., George, R., Goodling, R., Greenfield, R., Jorgensen, M. W., Lenkaitis, A., Reinemann, D., Saha, A., Sankaraiah, C., Shahinfar, S., Siberski, C., Wade, K. M., Zhang, F., ... Cabrera, V. E. (2021). Integrated Decision Support Systems (IDSS) for Dairy Farming: A Discussion on How to Improve Their Sustained Adoption. *Animals*, 11(7), 2025. <https://doi.org/10.3390/ani11072025>

Bonifazi, G., Corradini, E., Ursino, D., Virgili, L., Anceschi, E., & De Donato, M. C. (2022). A machine learning based sentient multimedia framework to increase safety at work. *Multimedia Tools and Applications*, 81(1), 141–169. <https://doi.org/10.1007/s11042-021-10984-z>

Bousdekis, A., Papageorgiou, N., Magoutas, B., Apostolou, D., & Mentzas, G. (2020). Sensor-driven Learning of Time-Dependent Parameters for Prescriptive Analytics. *IEEE Access*, 1–1. <https://doi.org/10.1109/ACCESS.2020.2994933>

Brennecke, M., Fridgen, G., Jöhnk, J., Radszuwill, S., & Sedlmeir, J. (2024). When Your Thing Won't Behave: Security Governance in the Internet of Things. *Information Systems Frontiers*. <https://doi.org/10.1007/s10796-024-10511-z>

Brzezińska, D., Bryant, P., & Markowski, A. S. (2019). An Alternative Evaluation and Indicating Methodology for Sustainable Fire Safety in the Process Industry. *Sustainability*, 11(17), 4693. <https://doi.org/10.3390/su11174693>

Bulut, M., & Özcan, E. (2024). Planning of prescriptive maintenance types for generator with fuzzy logic-based genetic algorithm in a hydroelectric power plant. *Expert Systems with Applications*, 240, 122480. <https://doi.org/10.1016/j.eswa.2023.122480>

Carvalho, J. N. D., Silva, F. R. D., & Nascimento, E. G. S. (2024). Challenges of the Biopharmaceutical Industry in the Application of Prescriptive Maintenance in the Industry 4.0 Context: A Comprehensive Literature Review. *Sensors*, 24(22), 7163. <https://doi.org/10.3390/s24227163>

Reference

Chaves Franz, M. L., Ayala, N. F., & Larranaga, A. M. (2024). Industry 4.0 for passenger railway companies: A maturity model proposal for technology management. *Journal of Rail Transport Planning & Management*, 32, 100480. <https://doi.org/10.1016/j.jrtpm.2024.100480>

Cho, A. D., Carrasco, R. A., & Ruz, G. A. (2022). Improving Prescriptive Maintenance by Incorporating Post-Prognostic Information Through Chance Constraints. *IEEE Access*, 10, 55924–55932. <https://doi.org/10.1109/ACCESS.2022.3177537>

Consilvio, A., Vignola, G., López Arévalo, P., Gallo, F., Borinato, M., & Crovetto, C. (2024). A data-driven prioritisation framework to mitigate maintenance impact on passengers during metro line operation. *European Transport Research Review*, 16(1), 6. <https://doi.org/10.1186/s12544-023-00631-z>

Cromie, S., & Bott, F. (2016). Just culture's "line in the sand" is a shifting one; an empirical investigation of culpability determination. *Safety Science*, 86, 258–272. <https://doi.org/10.1016/j.ssci.2016.03.012>

De Benedictis, A., Flammini, F., Mazzocca, N., Somma, A., & Vitale, F. (2023). Digital Twins for Anomaly Detection in the Industrial Internet of Things: Conceptual Architecture and Proof-of-Concept. *IEEE Transactions on Industrial Informatics*, 19(12), 11553–11563. <https://doi.org/10.1109/TII.2023.3246983>

Diez-Olivan, A., Del Ser, J., Galar, D., & Sierra, B. (2019). Data fusion and machine learning for industrial prognosis: Trends and perspectives towards Industry 4.0. *Information Fusion*, 50, 92–111. <https://doi.org/10.1016/j.inffus.2018.10.005>

Dutta, A., Karimi, I. A., & Farooq, S. (2022). PROAD (Process Advisor): A health monitoring framework for centrifugal pumps. *Computers & Chemical Engineering*, 163, 107825. <https://doi.org/10.1016/j.compchemeng.2022.107825>

Elele, U., Nekahi, A., Arshad, A., & Fofana, I. (2022). Towards Online Ageing Detection in Transformer Oil: A Review. *Sensors*, 22(20), 7923. <https://doi.org/10.3390/s22207923>

Elele, U., Nekahi, A., Arshad, A., Fofana, I., & McAulay, K. (2024). Oil Quality Index Model Verification and Validation Using Total Acid Number and Interfacial Tension Experimental Data. *IEEE Transactions on Dielectrics and Electrical Insulation*, 31(3), 1340–1349. <https://doi.org/10.1109/TDEI.2024.3357665>

Elfarri, E. M., Rasheed, A., & San, O. (2023). Artificial Intelligence-Driven Digital Twin of a Modern House Demonstrated in Virtual Reality. *IEEE Access*, 11, 35035–35058. <https://doi.org/10.1109/ACCESS.2023.3265191>

Esnaola-Gonzalez, I., Bermúdez, J., Fernandez, I., & Arnaiz, A. (2018). Semantic prediction assistant approach applied to energy efficiency in Tertiary buildings. *Semantic Web*, 9(6), 735–762. <https://doi.org/10.3233/SW-180296>

Fox, H., Pillai, A. C., Friedrich, D., Collu, M., Dawood, T., & Johanning, L. (2022). A Review of Predictive and Prescriptive Offshore Wind Farm Operation and Maintenance. *Energies*, 15(2), 504. <https://doi.org/10.3390/en15020504>

Gibey, G., Pahon, E., Zerhouni, N., & Hissel, D. (2024). Diagnostic and prognostic for prescriptive maintenance and control of PEMFC systems in an industrial framework. *Journal of Power Sources*, 613, 234864. <https://doi.org/10.1016/j.jpowsour.2024.234864>

Gnekpe, C., Tchunte, D., Nyawa, S., & Dey, P. K. (2024). Energy Performance of Building Refurbishments: Predictive and Prescriptive AI-based Machine Learning Approaches. *Journal of Business Research*, 183, 114821. <https://doi.org/10.1016/j.jbusres.2024.114821>

Goby, N., Brandt, T., & Neumann, D. (2023). Deep reinforcement learning with combinatorial actions spaces: An application to prescriptive maintenance. *Computers & Industrial Engineering*, 179, 109165. <https://doi.org/10.1016/j.cie.2023.109165>

Gordon, C. A. K., Burnak, B., Onel, M., & Pistikopoulos, E. N. (2020). Data-Driven Prescriptive Maintenance: Failure Prediction Using Ensemble Support Vector Classification for Optimal Process and Maintenance Scheduling. *Industrial & Engineering Chemistry Research*, 59(44), 19607–19622. <https://doi.org/10.1021/acs.iecr.0c03241>

Gordon, C. A. K., & Pistikopoulos, E. N. (2022). DATA-DRIVEN prescriptive maintenance toward FAULT-TOLERANT MULTIPARAMETRIC control. *AIChE Journal*, 68(6), e17489. <https://doi.org/10.1002/aic.17489>

