

Dampak Lean Terhadap Transformasi Digital: Analisis Maturitas Industri 4.0 Memanfaatkan Pembelajaran Mesin

Heribertus Ary Setyadi^{1*}, Galih Setiawan Nurohim², Wawan Nugroho³, Pudji Widodo⁴

^{1,2,3}Sistem Informasi Kampus Kota Surakarta, Universitas Bina Sarana Informatika, Indonesia

⁴ Teknologi Komputer Kampus Kabupaten Banyumas, Universitas Bina Sarana Informatika, Indonesia

Correspondence e-mail: heribertus.hbs@bsi.ac.id

ABSTRAK

Revolusi industri keempat membawa peluang sekaligus tantangan digital baru bagi dunia bisnis. Penelitian ini dilakukan untuk menganalisis status maturitas global Industri 4.0 guna mengidentifikasi tren spesifik, tantangan utama, dan potensi pertumbuhan industri. Teknik pembelajaran mesin tingkat lanjut diterapkan untuk menganalisis data, memproyeksikan peta jalan masa depan, serta memberikan rekomendasi yang disesuaikan demi meningkatkan kemampuan pengambilan keputusan strategis perusahaan. Tahap awal menggunakan Hierarchical Clustering untuk mengelompokkan data secara terstruktur, dilanjutkan dengan evaluasi model Decision Tree (DT), *Support Vector Machine*, dan *Random Forest*. Model *Decision Tree* (DT) terpilih sebagai model dengan performa terbaik dengan nilai MSE 0,032, MAE 0,063, dan skor R2 sebesar 0,862. Hasil analisis kuantitatif menunjukkan bahwa strategi optimasi jalur keputusan mampu meningkatkan level maturitas digital dari 1,177 menjadi 1,382, serta melalui jalur alternatif Efisiensi Waktu Perbaikan Deteksi Pemborosan meningkat signifikan dari 0,754 menjadi 1,42. Terkait pengaruh Lean, ditemukan bahwa variabel lean bukan merupakan faktor dominan yang memengaruhi skor maturitas secara langsung, melainkan lebih berperan dalam menentukan arah strategi implementasi perusahaan. Kontribusi ilmiah utama penelitian ini terletak pada integrasi model interdisipliner Digital Lean melalui algoritma *Decision Tree* (DT) untuk memproyeksikan estimasi peningkatan skor maturitas digital secara transparan melalui jalur intervensi yang terarah.

Kata Kunci: decision tree, lean, maturitas industri 4.0, pembelajaran mesin, transformasi digital

ABSTRACT

The fourth industrial revolution presents distinct digital opportunities and challenges for the business sector. This research assesses the global maturity status of Industry 4.0 to identify industry-specific trends, critical challenges, and growth potential. Advanced machine learning techniques are deployed for data analysis, future roadmap projection, and the provision of tailored recommendations to enhance strategic corporate decision-making. The initial phase leverages Hierarchical Clustering for structured data grouping, followed by the evaluation of Decision Tree (DT), Support Vector Machine, and Random Forest models. The Decision Tree (DT) model was identified as the optimal model, achieving an MSE of 0.032, MAE of 0.063, and an R2 score of 0.862. Quantitative results demonstrate that the proposed path optimization strategy can elevate the digital maturity level from 1.177 to 1.382, while an alternative path focusing on Time Efficiency-Waste Detection Improvement significantly increases it from 0.754 to 1.42. Regarding the impact of Lean, the findings indicate that the lean variable is not a dominant factor directly affecting the maturity score, but rather plays a pivotal role in shaping the implementation strategy (pp. 9-10). The primary scientific contribution of this study lies in the integration of an interdisciplinary Digital Lean model via the Decision Tree (DT) algorithm to transparently project digital maturity score advancements through targeted intervention paths.

Keywords: decision tree, digital transformation, industry 4.0 maturity, lean, machine learning



1. PENDAHULUAN

Ekspansi Industri 4.0, yang secara intrinsik terkait dengan paradigma smart factory, mengintegrasikan teknologi mutakhir seperti *Internet of Things* (IoT), kecerdasan buatan (AI), robotika, manufaktur aditif (cetak 3D), dan komputasi awan ke dalam operasional bisnis. Transformasi ini merevolusi model operasional dan interaksi ekosistem perusahaan, yang menandai fase baru manufaktur berbasis fleksibilitas, inovasi, dan keberlanjutan (Jaskó, 2025). Sebagaimana dinyatakan dalam (Surindra et al., 2024), urgensi dan sifat revolusioner Industri 4.0 didasarkan pada lima alasan fundamental: (1) fleksibilitas bisnis dalam merespons dinamika pasar berkat sistem otomatisasi, (2) peningkatan akselerasi inovasi dan produktivitas, (3) reposisi konsumen sebagai titik sentral proses produksi, (4) pergeseran peran tenaga kerja yang memerlukan adaptasi keterampilan baru, serta (5) potensinya dalam mewujudkan kemakmuran berkelanjutan melalui solusi teknologi mutakhir untuk isu lingkungan dan sosial-ekonomi. Perusahaan berupaya menyelaraskan diri dengan tren Industri 4.0 yang sedang berkembang guna menjaga daya saing di pasar. Untuk mencapai hal tersebut, sangat penting bagi perusahaan untuk menilai tingkat maturitas saat ini dan menyusun peta jalan (*roadmap*) yang jelas guna melakukan perbaikan (Elnadi & Omar, 2022).

Perusahaan dapat memperoleh perspektif strategis dengan mengidentifikasi faktor-faktor penentu tingkat maturitas dalam kerangka Industri 4.0. Secara lebih mendalam, menganalisis apakah perusahaan dengan maturitas lean yang mapan lebih siap dalam mengakselerasi maturitas Industri 4.0 sebagai langkah yang strategis. Dengan kata lain, transisi menuju level Industri 4.0 yang lebih tinggi dapat berlangsung lebih optimal (lebih singkat dan efisien dari sisi biaya) apabila perusahaan telah memiliki fondasi maturitas yang kuat pada aspek tersebut. Sejauh literatur yang telah dipelajari, Sebagian besar penelitian terdahulu berfokus pada hubungan antara Lean dan adopsi Industri 4.0 atau dampaknya terhadap kinerja organisasi. Namun, penelitian yang menganalisis pengaruh tingkat maturitas Lean terhadap maturitas Industri 4.0 menggunakan pendekatan machine learning serta menghasilkan rekomendasi peningkatan maturitas masih terbatas. Sebagian besar penelitian terdahulu baru berfokus pada hubungan umum antara produksi Lean dan adopsi Industri 4.0 (Komkowski et al., 2023), (Maware & li, 2023) atau sekadar mengidentifikasi pola variasi transformasi digital (Costa et al., 2025). Namun, penelitian-penelitian tersebut memiliki keterbatasan karena belum memerinci bagaimana tingkat maturitas Lean memengaruhi perkembangan maturitas Industri 4.0 secara bertahap, serta belum mampu menyediakan peta jalan (*roadmap*) perbaikan yang aplikatif bagi perusahaan. Perbedaan mendasar penelitian ini dengan studi terdahulu terletak pada penggunaan pendekatan pembelajaran mesin (*machine learning*) dua tahap yang dinamis untuk mengekstrak rekomendasi preskriptif secara personal berdasarkan karakteristik unik masing-masing perusahaan.

Para penulis dalam (Chen et al., 2023) melakukan wawancara dengan sejumlah perusahaan guna mengeksplorasi keterkaitan antara praktik lean dan Industri 4.0. Cakupan investigasi ini meliputi tiga dimensi utama: implementasi lean, teknologi Industri 4.0, dan indikator performa perusahaan. Hasil studi menunjukkan bahwa penggabungan praktik Lean dengan adopsi Industri 4.0 memicu peningkatan kinerja operasional yang berarti. Lebih lanjut, teramati bahwa praktik lean sangat menonjol pada perusahaan yang mengalami perbaikan kinerja operasional tinggi, sementara adopsi Industri 4.0 secara mandiri tidak berhubungan signifikan dengan perbaikan tersebut. Meski demikian, terdapat korelasi yang jelas antara adopsi Industri 4.0 dan penerapan praktik lean. Walaupun penelitian ini menitikberatkan pada hubungan antara produksi lean, Industri 4.0, dan kinerja operasional, namun belum menyajikan peta jalan terperinci maupun rekomendasi perbaikan bagi perusahaan. Dalam penelitian kali ini akan menjawab keterbatasan tersebut dengan menyusun strategi pengembangan yang lebih aplikatif.

Merujuk pada (Solikhah et al., 2024), pengategorian perusahaan berdasarkan komitmen lean menunjukkan dua pola transformasi digital yang berbeda: pola *Sustaining* (digitalisasi horizontal bertahap) dan pola *Disruptive* (investasi digital vertikal yang signifikan). Studi ini memberikan wawasan penting bagi akademisi dan praktisi mengenai variasi strategi digitalisasi. Walaupun artikel tersebut mengidentifikasi perbedaan perilaku adopsi Industri 4.0 antara perusahaan dengan tingkat lean tinggi dan rendah, cakupannya masih terbatas pada identifikasi pola. Penelitian terdahulu tidak membahas kontribusi variabel lain beserta pengaruhnya terhadap tingkat maturitas Industri 4.0. Sebaliknya, model yang diajukan dalam penelitian kali ini mampu mengidentifikasi sekaligus menganalisis berbagai faktor tersebut. Dengan demikian, pendekatan ini memiliki karakteristik yang dinamis dan personal, yang dirancang agar selaras dengan objektif spesifik dan kebutuhan internal perusahaan (Castagnoli et al.,

2022). Pemanfaatan kecerdasan buatan (AI) ditujukan untuk memetakan variabel kunci yang memengaruhi maturitas Industri 4.0, dengan fokus utama pada penilaian pengaruh lean. Penggunaan AI dipilih atas dasar kapabilitasnya dalam membedah pola rumit, mengidentifikasi korelasi nonlinier, dan fleksibilitasnya terhadap perubahan data (Tashkinov, 2025). Terlebih lagi, AI memfasilitasi pembuatan model prediksi dan preskripsi untuk memproyeksikan tren mendatang serta merumuskan langkah-langkah strategis. Sebagai kesimpulan, metodologi berbasis AI ini menyediakan solusi yang andal dan fleksibel untuk menganalisis sekaligus mengoptimalkan level maturitas Industri 4.0 dalam sektor bisnis (Yang et al., 2025).

Penelitian kali ini diarahkan untuk membedah variabel utama yang memengaruhi maturitas perusahaan dalam kerangka Industri 4.0. Memvalidasi apakah keamanan praktik lean menjadi prasyarat atau faktor pendukung bagi maturitas Industri 4.0. Eksplorasi terhadap model maturitas khusus digital lean turut dilakukan untuk memperkaya kerangka kerja penelitian. Untuk mencapai tujuan tersebut, maka diadopsi pendekatan pembelajaran mesin dalam dua tahap. Pertama, metode Hierarchical Clustering digunakan untuk pengelompokan data dan augmentasi. Kedua, serangkaian teknik supervised ML diuji, dengan fokus pada *Decision Tree* (DT), *Support Vector Machine* (SVM), dan *Random Forest* (RF) sebagai alat analisis prediktif, serta penggunaan kembali *Decision Tree* (DT) untuk fungsi deskriptif dan rekomendatif.

Model maturitas umumnya diterapkan untuk mengevaluasi kondisi eksis, menyusun skala prioritas perbaikan, serta memonitor progres pada bidang tertentu. Secara konseptual, model ini disusun sebagai rangkaian tingkatan atau tahapan yang menyederhanakan deskripsi perkembangan suatu objek. Sejalan dengan penelitian dalam (Angreani et al., 2024), model ini memfasilitasi penentuan tingkat maturitas aktual dan target yang ingin dicapai beserta langkah mitigasinya. Demikian pula, (Jamwal et al., 2025) menempatkan model maturitas sebagai instrumen peningkatan berkelanjutan (*continuous improvement*) bagi organisasi. Meski memiliki struktur variatif, model maturitas pada dasarnya berpijak pada dua elemen utama: urutan level dan dimensi kapabilitas. Pada dasarnya, model maturitas bersifat multidimensi. Sebagai contoh, dalam menilai maturitas perusahaan dalam konteks Industri 4.0, pertimbangan mencakup berbagai dimensi seperti proses, personel, dan teknologi. Demikian pula dalam evaluasi perusahaan berdasarkan maturitas rantai pasok, dimensi seperti logistik balik (*reverse logistics*), kolaborasi, proses, teknologi, dan keberlanjutan menjadi aspek yang relevan (Rahardjo et al., 2023). Pemilihan dimensi yang akan dievaluasi sangat bergantung pada domain spesifik yang sedang diteliti. Merujuk pada (Jamari & Fedouaki, 2025) terdapat tiga klasifikasi utama model maturitas berdasarkan fungsinya. Kategori deskriptif menitikberatkan pada penilaian status maturitas saat ini sebagai dasar identifikasi area yang memerlukan perhatian khusus. Selanjutnya, kategori rekomendatif menawarkan panduan aplikatif bagi perusahaan untuk mencapai level yang lebih tinggi. Terakhir, kategori komparatif memfasilitasi analisis komparasi atau perbandingan kinerja dengan organisasi lain menggunakan data sekunder maupun historis yang tersedia.

Prinsip perbaikan terus-menerus merupakan pondasi dari metodologi lean. Dalam kerangka ini, model maturitas berfungsi sebagai instrumen vital untuk menilai posisi maturitas lean organisasi saat ini guna memetakan kesenjangan yang ada. Hasil identifikasi tersebut kemudian menjadi dasar dalam menetapkan sasaran perbaikan, sehingga level maturitas lean perusahaan dapat terus ditingkatkan (Krissensen & Amrina, 2025). Terdapat 24 model kunci yang dikaji secara mendalam. Koleksi model ini mencakup LCMM yang merepresentasikan maturitas LC secara eksplisit melalui pendekatan penilaian yang sistematis. Sebagian model lainnya secara tegas mempertimbangkan lean construction sebagai fondasi utama. Sementara itu, tiga model tambahan teridentifikasi tidak memiliki tautan langsung ke maturitas LC, namun tetap mengadopsi prinsip lean dan fleksibilitas penerapannya dalam skema model tersebut (Pangestu et al., 2024).

Kebutuhan akan model maturitas baru muncul dari integrasi kedua paradigma yang memperhitungkan korelasi antara lean dan industri 4.0. Sejauh ini, literatur mengenai model maturitas lean 4.0 masih sangat terbatas. Walaupun terdapat penelitian yang mengintegrasikan prinsip lean dengan BIM untuk menghasilkan wawasan proyek yang komprehensif, studi yang secara spesifik membahas konvergensi lean dan industri 4.0 dalam skema model maturitas masih sangat minim (Purnama & Cahyo, 2025). Hingga saat ini, literatur mencatat bahwa artikel (Treviño-elizondo & Garc, 2023) yang dipublikasikan pada tahun 2023 adalah satu-satunya penelitian yang memperkenalkan model maturitas digital lean dalam domain tersebut. Penelitian ini mengembangkan model maturitas yang menyinergikan lean dan industri 4.0 melalui empat elemen inti: pilar strategis, dimensi perspektif, serta tingkatan

maturitas. Pilar lean dan industri 4.0 bertindak sebagai landasan utama kerangka kerja, sementara perspektif 'Smart' yang mencakup proses, sumber daya manusia, dan produk berfungsi memberikan analisis organisasi yang menyeluruh. Tingkat maturitas dalam model ini dibedakan menjadi maturitas strategis dan maturitas 'Smart', yang memungkinkan evaluasi sistematis terhadap perkembangan organisasi di setiap aspek terkait.

Berdasarkan permasalahan yang telah diuraikan, penelitian ini diarahkan untuk mencapai tujuan utama yaitu menganalisis status maturitas global Industri 4.0 serta menguji pengaruh tingkat maturitas Lean terhadap transformasi digital perusahaan memanfaatkan teknik pembelajaran mesin tingkat lanjut. Tujuan pendukung antara lain: 1) Memetakan variabel-variabel kunci dan korelasi multivariat yang mendominasi skor maturitas Industri 4.0, 2) Mengevaluasi dan membandingkan performa model prediktif (*Decision Tree*, *Support Vector Machine*, dan *Random Forest*) untuk mendapatkan algoritma optimal dan 3) Menyusun model rekomendasi preskriptif berupa jalur intervensi yang konkret untuk mendorong estimasi skor maturitas digital perusahaan.

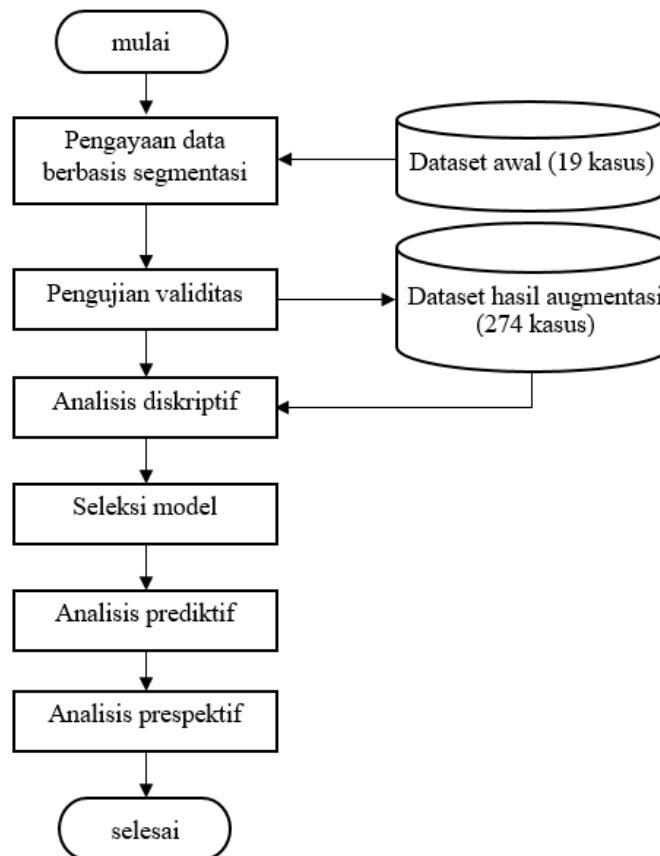
Kontribusi utama dan novelty dari penelitian ini dirumuskan ke dalam beberapa aspek berikut: menggabungkan pilar budaya Lean thinking tradisional dengan adopsi teknologi Industri 4.0 ke dalam satu model maturitas yang terpadu, memanfaatkan algoritma *Decision Tree* untuk menghasilkan proyeksi estimasi skor maturitas secara transparan melalui cabang keputusan yang mudah diinterpretasikan oleh pihak manajemen, menerapkan teknik kombinasi *Hierarchical Clustering* dan augmentasi berbasis segmentasi untuk mengatasi keterbatasan data pada studi kasus Industri 4.0, dan menyediakan peta rute investasi digital yang konkret dan preskriptif bagi perusahaan berdasarkan kluster karakteristik operasional.

2. METODE PENELITIAN

Metodologi penelitian digambarkan melalui diagram alir pada Gambar 1. Tahap awal melibatkan pengumpulan basis data yang kredibel. Karena keterbatasan akses terhadap data riil proyek Lean 4.0 akibat isu kerahasiaan industri, digunakan dataset sekunder dari referensi (Rossini et al., 2022) yang terdiri atas 19 perusahaan dan 53 atribut. Meskipun ukuran sampel terbatas, dataset ini dipilih karena memiliki dimensi atribut yang kaya dan telah tervalidasi untuk menggambarkan karakteristik Lean 4.0. Untuk memenuhi kebutuhan data dalam pengembangan model pembelajaran mesin yang efisien serta menghindari risiko overfitting akibat keterbatasan sampel (*small dataset problem*), dilakukan teknik augmentasi data berbasis segmentasi. Pendekatan ini merupakan solusi metodologis yang valid untuk mereplikasi variasi data berdasarkan pola segmen karakteristik dari data asli. Teknik ini berhasil meningkatkan jumlah data dari 19 menjadi 274 perusahaan. Selanjutnya, validitas data teraugmentasi diverifikasi dengan menghitung persentase hubungan antar-atribut yang tetap terjaga pada data yang dihasilkan sebelum data tersebut diintegrasikan ke dalam analisis.

Prosedur analisis data dalam penelitian ini dilakukan melalui tiga tahapan utama secara berurutan. Tahap pertama adalah analisis deskriptif yang menggunakan *Multiple Correspondence Analysis* (MCA) dan matriks korelasi Pearson untuk memetakan hubungan antaratribut dalam dataset. Tahap kedua adalah pemodelan prediktif yang dilakukan dengan melatih dan mengevaluasi *algoritma Decision Tree* (DT), *Random Forest* (RF), dan *Support Vector Machine* (SVM) menggunakan data hasil augmentasi. Selanjutnya, tahap ketiga adalah analisis perspektif yang memanfaatkan struktur pohon keputusan dari model DT terpilih untuk mengekstrak aturan keputusan dan menyusun rekomendasi peningkatan maturitas. Pemilihan model pembelajaran mesin yang paling sesuai dilakukan untuk memastikan proses ekstraksi wawasan dari data berjalan secara efektif dan menghasilkan informasi yang dapat mendukung pengambilan keputusan.

Pada tahap analisis deskriptif, penelitian berfokus pada identifikasi pola hubungan dan korelasi antaratribut serta penentuan faktor-faktor yang memiliki pengaruh paling signifikan terhadap tingkat maturitas Industri 4.0. Tahap pemodelan prediktif bertujuan untuk memprediksi tingkat maturitas perusahaan berdasarkan karakteristik dan pola yang ditemukan pada data historis melalui penerapan algoritma pembelajaran mesin. Sementara itu, tahap analisis perspektif diarahkan pada penyusunan rekomendasi yang bersifat preskriptif dan personal untuk meningkatkan tingkat maturitas perusahaan berdasarkan wawasan yang diperoleh dari model terpilih



Gambar 1. Diagram Alur Penelitian

Merujuk pada penelitian (Rossini et al., 2022) mengenai perbedaan adopsi teknologi Industri 4.0 berdasarkan tingkat maturitas lean, penelitian ini menggunakan dataset serupa untuk membangun model maturitas pembelajaran mesin. Model ini berfungsi sebagai alat prediksi tingkat maturitas dan penyedia rekomendasi personal bagi perusahaan.

Deskripsi dataset

Basis data yang digunakan terdiri atas 19 kasus riil dan 53 atribut. Observasi terhadap perusahaan difokuskan hanya pada dua sektor utama, yaitu sektor Mesin (M) dan Produk Logam (PL). Tingkat maturitas lean dari 19 perusahaan ini dibedakan menjadi dua, yakni tingkat nol bagi perusahaan dengan maturitas rendah dan tingkat satu bagi yang memiliki maturitas tinggi. Seluruh atribut dikelompokkan ke dalam empat kategori dimensi: Implementasi teknologi dan maturitas Industri 4.0, Area investasi Industri 4.0, Motivasi dan proyeksi kinerja investasi Industri 4.0, serta besaran nilai investasi Industri 4.0. Sub-dimensi dari tiap kategori tersebut ditetapkan sebagai variabel penyusun model.

Basis data ini mengadopsi empat level maturitas (Tabel 1) guna mengevaluasi enam pilar teknologi Industri 4.0: *Internet of Things* (IoT), analitik industri, antar muka manusia-mesin, manufaktur awan, manufaktur aditif, serta Otomasi tingkat lanjut. Keenam teknologi tersebut diklasifikasikan sebagai sub dimensi dalam kategori utama 'Teknologi dan Tingkat Maturitas Industri 4.0'.

Tabel 1. Jenjang Maturitas

Jenjang	Keterangan
Tingkat 0	Tidak Tersedia
Tingkat 1	Monitoring
Tingkat 2	Kontrol
Tingkat 3	Kontrol / Otonomi Optimasi
Tingkat 4	Otonomi Optimasi

Penelitian ini bertujuan untuk mengevaluasi tingkat maturitas perusahaan secara menyeluruh dengan mempertimbangkan berbagai teknologi tersebut. Sehubungan dengan hal itu, tingkat maturitas individual dari setiap teknologi diusulkan untuk digantikan oleh satu nilai maturitas agregat. Nilai ini dihitung berdasarkan rata-rata tertimbang dari tingkat maturitas keenam teknologi tersebut. Bobot untuk masing-masing teknologi merujuk pada penelitian (Bhadu et al., 2023) yang ditetapkan menggunakan metode *Analytic Hierarchy Process* (AHP). Rincian faktor pembobotan terdiri dari tingkat maturitas IoT: 16%; tingkat maturitas Analitik Industri: 18,9%; tingkat maturitas Antarmuka Manusia-Mesin Tingkat Lanjut: 40,3%; tingkat maturitas Manufaktur Awan: 12,1%; tingkat maturitas Manufaktur Aditif: 3,8%; tingkat maturitas Otomasi Tingkat Lanjut: 3,3%; tingkat maturitas simulasi: 5,4%.

Nilai agregat ini dihitung berdasarkan rata-rata tertimbang dari tingkat maturitas keenam teknologi tersebut menggunakan rumus pada Persamaan (1):

$$\text{Overall Maturity Level} = \sum_{i=1}^n (W_i \times M_i) \quad (1)$$

Secara eksplisit, substitusi nilai bobot AHP ke dalam Persamaan (1) adalah sebagai berikut:

$$\text{Overall Maturity Level} = (0,16 \times \text{IoT}) + (0,189 \times \text{analitik}) + (0,403 \times \text{HMI}) + (0,121 \times \text{cloud}) + (0,038 \times \text{aditif}) + (0,033 \times \text{otomasi})$$


Validasi bobot dilakukan melalui penghitungan indeks konsistensi pada matriks perbandingan terkait. Hasil rasio sebesar 0,019 menunjukkan bahwa penilaian dalam penghitungan bobot bersifat konsisten, karena nilainya masih di bawah ambang batas standar 0,1. Berdasarkan ketiadaan referensi mengenai teknologi 'Simulasi' pada instrumen survei, analisis ini tidak mengikutsertakan variabel tersebut. Karena tidak merepresentasikan data riil dalam survei, 'Simulasi' diberi nilai 0 dan dikeluarkan dari komponen perhitungan 'Tingkat Maturitas Keseluruhan'. Singkatnya, sebuah kolom baru bernama ['Overall Maturity Level'] telah ditambahkan ke dalam dataset untuk menggantikan enam kolom tingkat maturitas teknologi individual. Nilai pada kolom ini diperoleh dari hasil penjumlahan tertimbang tingkat maturitas di seluruh teknologi tersebut sesuai dengan prosedur yang telah dipaparkan sebelumnya.

Augmentasi Data Berbasis Segmentasi Data

Dataset yang digunakan dalam penelitian ini memiliki ukuran yang relatif terbatas, yaitu hanya terdiri atas 19 kasus perusahaan. Kondisi tersebut berpotensi menghambat pengembangan model pembelajaran mesin yang memiliki kemampuan generalisasi yang baik. Oleh karena itu, diterapkan teknik augmentasi data untuk menghasilkan sampel tambahan yang dapat memperkaya variasi data dan meningkatkan efektivitas proses pelatihan model. Pendekatan yang digunakan adalah augmentasi berbasis segmentasi data, yaitu proses pembangkitan data sintesis yang mempertimbangkan karakteristik kelompok data yang memiliki kemiripan tertentu. Metode ini dipilih karena sesuai untuk data tabular, mengingat kemampuannya dalam mempertahankan struktur hubungan antarvariabel sekaligus menghasilkan variasi data yang tetap merepresentasikan pola pada dataset asli.

Proses augmentasi diawali dengan penerapan klasterisasi hierarki untuk mengelompokkan perusahaan berdasarkan tingkat kemiripan karakteristiknya. Jumlah klaster optimal ditentukan menggunakan metode elbow dan menghasilkan tiga klaster sebagai struktur segmentasi data. Selanjutnya, setiap observasi dialokasikan ke dalam klaster yang sesuai menggunakan algoritma Agglomerative Clustering dengan pendekatan bottom-up. Setelah proses segmentasi selesai, dibangun fungsi augmentasi yang menggunakan dataset asli sebagai dasar pembentukan sampel baru. Proses ini dilakukan dengan mengiterasi seluruh atribut, kecuali atribut target dan atribut klaster, kemudian menghasilkan data sintesis melalui pemilihan klaster dan observasi secara acak yang tetap mempertahankan karakteristik data pada kelompok yang sama. Nilai atribut kemudian dimodifikasi menggunakan kombinasi nilai yang berasal dari data asli sehingga diperoleh variasi data baru yang tetap konsisten dengan pola segmentasinya. Hasil dari proses tersebut adalah dataset teraugmentasi yang memiliki jumlah observasi lebih besar dan siap digunakan pada tahap pemodelan pembelajaran mesin.

Dendrogram pada Gambar 2 memperlihatkan hasil pengelompokan perusahaan berdasarkan tingkat kemiripan data. Tingkat kedekatan antarperusahaan direpresentasikan oleh panjang garis vertikal, di mana garis yang lebih pendek menunjukkan kemiripan yang lebih tinggi. Berdasarkan hasil analisis, perusahaan 17 dan perusahaan 5 merupakan pasangan dengan tingkat kemiripan tertinggi, yang ditunjukkan oleh penggabungan keduanya pada jarak klasterisasi yang paling rendah.



Gambar 2. Dendrogram Perusahaan: Analisis Similaritas dan Klusterisasi Hierarki

Jumlah kluster untuk data penelitian ini ditentukan dengan menggunakan metode siku (*elbow method*). Metode ini melibatkan pemplotan nilai *within-cluster sum of squares* (WCSS) terhadap jumlah kluster, kemudian mengidentifikasi titik di mana laju penurunan WCSS mulai melambat hingga membentuk struktur menyerupai 'siku' pada grafik. Berdasarkan analisis yang dilakukan, titik siku tersebut teramati pada jumlah tiga kluster. Tahap berikutnya adalah menerapkan teknik augmentasi data pada setiap kluster. Ukuran data hasil augmentasi tersebut mencapai 275 entitas.

Metode analisis korelasi multivariat diusulkan guna menguji tingkat kemiripan (*fidelity*) antara data sintetis dan data riil. Prosedur ini membandingkan matriks *Pairwise Pearson Correlation* melalui visualisasi *heatmap*. *Heatmap* sendiri adalah representasi visual data yang menggunakan gradasi warna untuk menunjukkan intensitas nilai individu (Hernandez et al., 2023). Distribusi nilai pada dimensi baris dan kolom umumnya divisualisasikan untuk mempermudah analisis. Persentase hubungan yang terjaga pada data teraugmentasi ditentukan berdasarkan penghitungan selisih korelasi antar-dataset. Kualitas pendekatan dikategorikan sebagai 'Sangat Baik' jika nilai tersebut di atas 0,6, 'Baik' untuk rentang 0,4–0,6, dan 'Buruk' jika di bawah 0,4. Berdasarkan hasil analisis, persentase hubungan numerik yang tetap terjaga pada data teraugmentasi adalah 0,43, sehingga pendekatan ini dikategorikan sebagai 'Baik'. Hasil tersebut mengonfirmasi bahwa data sintetis secara memadai mampu merepresentasikan pola hubungan multivariat yang terdapat pada data asli. Meskipun analisis korelasi ini berfokus pada kekuatan hubungan linear antar-atribut, pendekatan ini dinilai krusial dan memadai untuk memvalidasi data teraugmentasi dalam penelitian ini. Hal ini disebabkan oleh sifat model Decision Tree yang akan digunakan pada tahap berikutnya, yang sangat bergantung pada stabilitas struktur hubungan dan interaksi antar-fitur (53 atribut) untuk membangun cabang keputusan yang akurat.

Model dan Teknik Penelitian

Sebagaimana ditunjukkan pada Gambar 1, analisis dalam penelitian ini diawali dengan analisis deskriptif, dilanjutkan dengan analisis prediktif, dan diakhiri dengan analisis perspektif. Setiap tahapan dalam proses ini memerlukan teknik yang berbeda. Untuk analisis deskriptif, dipilih *Multiple Component Analysis* (MCA) untuk analisis multidimensi dan *heatmap* untuk visualisasi korelasi. Penggunaan metode ini bertujuan untuk mencapai dua sasaran: (1) mengidentifikasi fitur relevan melalui eliminasi redundansi pada pasangan fitur berkorelasi tinggi guna memurnikan data input model dan menghindari *overfitting*; serta (2) memetakan hubungan antara fitur dengan tingkat maturitas perusahaan untuk menentukan area perbaikan bagi entitas berkinerja rendah. Implementasi model ML menjadi instrumen utama dalam merealisasikan analisis prediktif ini.


Dalam penelitian ini, digunakan tiga algoritma pembelajaran mesin, yaitu DT, RF, dan SVM, untuk melakukan analisis prediktif dalam memperkirakan tingkat maturitas perusahaan. Pemilihan ketiga algoritma tersebut didasarkan pada karakteristik dan keunggulan masing-masing dalam menangani data dengan kompleksitas yang berbeda. Selain itu, penggunaan beberapa model memungkinkan dilakukan perbandingan performa guna mengidentifikasi algoritma yang paling sesuai untuk memodelkan hubungan antara variabel-variabel penelitian dan tingkat maturitas Industri 4.0.

DT dipilih karena memiliki struktur yang transparan dan mudah diinterpretasikan, sehingga mampu menjelaskan proses pengambilan keputusan secara eksplisit. Model ini bekerja dengan menentukan atribut pemisah terbaik pada setiap simpul menggunakan metrik seperti Gini impurity atau entropy, kemudian membagi data secara rekursif hingga memenuhi kriteria penghentian tertentu. Sementara itu, RF digunakan karena kemampuannya meningkatkan akurasi prediksi dan mengurangi risiko overfitting melalui pendekatan ansambel yang menggabungkan sejumlah pohon keputusan. Model ini membangun banyak pohon menggunakan sampel data yang dipilih secara acak (bootstrapping), kemudian menggabungkan hasil prediksi seluruh pohon melalui mekanisme agregasi untuk menghasilkan prediksi akhir yang lebih stabil. Adapun SVM dipilih karena efektif dalam menangani permasalahan klasifikasi yang bersifat linier maupun nonlinier. Algoritma ini bekerja dengan mencari hyperplane optimal yang mampu memisahkan kelas dengan margin terbesar, serta dapat memetakan data ke ruang fitur berdimensi lebih tinggi melalui fungsi kernel untuk meningkatkan kemampuan separasi pada pola data yang kompleks.

3. HASIL DAN PEMBAHASAN

3.1. Analisis deskriptif

Mengingat dataset ini memuat variabel kategorikal, teknik *Multiple Correspondence Analysis* (MCA) diterapkan untuk melakukan analisis multidimensi. Metode ini mereduksi sekumpulan variabel kategorikal menjadi sejumlah kecil variabel independen yang disebut komponen utama. Komponen-komponen ini berfungsi merangkum informasi data secara optimal.



Gambar 3. Visualisasi Peta Faktor MCA untuk Variabel-Variabel Kunci


Hasil MCA pada Gambar 3 menunjukkan adanya pengelompokan perusahaan yang mencerminkan karakteristik maturitas Industri 4.0 yang berbeda. Pada sisi kanan atas grafik, perusahaan-perusahaan cenderung membentuk klaster yang rapat, mengindikasikan tingkat kemiripan yang tinggi antar anggota kelompok. Karakteristik utama klaster ini ditunjukkan oleh tingginya tingkat maturitas pada analitik industri tingkat lanjut, otomasi tingkat lanjut, IoT, dan *human-machine interface* (HMI). Selain itu, perusahaan-perusahaan dalam kelompok ini juga menerapkan intervensi jangka panjang secara ekstensif. Temuan tersebut sejalan dengan hasil penelitian sebelumnya yang menunjukkan bahwa perusahaan yang berfokus pada intervensi jangka panjang cenderung memiliki tingkat maturitas teknologi Industri 4.0 yang lebih tinggi meskipun tingkat maturitas lean yang dimiliki relatif lebih rendah. Dengan demikian, klaster ini dapat diidentifikasi sebagai kelompok perusahaan yang telah mencapai tingkat kematangan teknologi yang lebih maju dalam implementasi Industri 4.0.

Sebaliknya, perusahaan-perusahaan yang berada pada sisi kiri atas grafik membentuk klaster tersendiri dengan karakteristik yang berbeda. Kedekatan posisi antarperusahaan pada area ini menunjukkan adanya kesamaan pola investasi dan strategi implementasi. Kelompok ini dicirikan oleh preferensi terhadap intervensi lokal dalam jangka menengah, tingginya investasi pada aspek logistik

Industri 4.0, tingkat maturitas otomasi tingkat lanjut yang masih rendah (Level 0), serta orientasi yang kuat terhadap prinsip-prinsip lean. Pola tersebut mengindikasikan bahwa perusahaan dengan tingkat maturitas lean yang lebih tinggi cenderung memprioritaskan investasi pada peningkatan logistik dibandingkan pengembangan otomasi tingkat lanjut. Hasil ini menunjukkan bahwa kematangan lean tidak selalu diikuti oleh tingkat maturitas teknologi Industri 4.0 yang tinggi, melainkan lebih berpengaruh terhadap arah dan strategi implementasi transformasi digital yang dipilih perusahaan.

Setelah analisis grafik MCA selesai dieksplorasi, pembahasan selanjutnya beralih pada analisis heatmap. Transisi dari grafik MCA ke heatmap ini memiliki fungsi penting dalam analisis. Jika grafik MCA menyajikan gambaran umum hubungan antarvariabel kategoris, heatmap memfasilitasi pemeriksaan interaksi dan korelasi spesifik secara lebih mendalam. Pola, ketergantungan, serta area potensial yang signifikan dapat diidentifikasi secara langsung melalui visualisasi data ini.

Menurut referensi, heatmap (matriks korelasi) merupakan komponen penting yang dibutuhkan bagi peneliti lain untuk mereproduksi sekaligus mengonfirmasi hasil studi, serta untuk melakukan analisis sekunder. Dalam penelitian ini, heatmap digunakan sebagai instrumen utama untuk melaksanakan analisis deskriptif pada dataset. Metode ini menawarkan cara intuitif untuk merangkum dan mengeksplorasi sebaran variabel kuantitatif guna mengenali tren yang menonjol. Dengan merepresentasikan nilai data melalui perbedaan warna, heatmap menyajikan wawasan instan terkait ukuran nilai dan hubungan posisi antarvariabel atau hasil pengamatan yang diuji.



Gambar 4. Visualisasi Fokus Heatmap Parsial (Matriks Korelasi)

Hasil analisis korelasi memberikan pemahaman mengenai faktor-faktor yang berhubungan dengan tingkat maturitas teknologi Industri 4.0. Korelasi positif terkuat ditemukan antara tingkat maturitas keseluruhan dan investasi pada proses perakitan dengan nilai sebesar 0,61. Temuan ini menunjukkan bahwa peningkatan investasi teknologi pada aktivitas perakitan berkaitan dengan meningkatnya tingkat maturitas Industri 4.0 perusahaan. Selain itu, penggunaan insentif pemerintah untuk tujuan kualitas dan produktivitas juga menunjukkan hubungan positif dengan tingkat maturitas keseluruhan, masing-masing sebesar 0,46 dan 0,41. Hasil tersebut mengindikasikan bahwa dukungan finansial maupun kebijakan pemerintah dapat menjadi faktor pendorong dalam peningkatan kapabilitas teknologi perusahaan. Korelasi positif sebesar 0,41 juga ditemukan antara tingkat maturitas keseluruhan dan pelaksanaan intervensi teknologi yang luas dalam jangka panjang (Extensive Intervention–Long Time), yang menunjukkan bahwa implementasi transformasi digital secara berkelanjutan berkontribusi terhadap pencapaian tingkat maturitas Industri 4.0 yang lebih tinggi.

Sebaliknya, beberapa variabel menunjukkan hubungan yang sangat lemah dengan tingkat maturitas Industri 4.0. Korelasi antara fleksibilitas dan peningkatan deteksi pemborosan hanya sebesar 0,01, yang mengindikasikan hampir tidak adanya hubungan linier antara kedua variabel tersebut. Nilai korelasi yang sama juga ditemukan pada hubungan antara tingkat maturitas keseluruhan dan investasi Industri 4.0 pada area pemrosesan. Temuan ini menunjukkan bahwa tidak semua inisiatif atau area investasi memberikan kontribusi yang signifikan terhadap peningkatan maturitas Industri 4.0. Lebih lanjut, hasil analisis mengindikasikan bahwa variabel Lean bukan merupakan faktor dominan yang secara langsung memengaruhi skor maturitas Industri 4.0. Meskipun terdapat perbedaan pendekatan implementasi antara perusahaan dengan tingkat maturitas Lean rendah dan tinggi, tingkat maturitas Industri 4.0 yang dicapai relatif serupa. Dengan demikian, Lean lebih berperan sebagai faktor yang memengaruhi arah dan strategi implementasi transformasi digital dibandingkan sebagai penentu langsung tingkat maturitas Industri 4.0.

Berbagai inisiatif yang dilakukan tidak serta-merta mencerminkan tingkat maturitas Industri 4.0 yang tinggi, mengingat faktor-faktor tersebut memiliki pengaruh terbatas terhadap skor maturitas total. Sejalan dengan hal tersebut, korelasi rendah pada investasi pemrosesan menunjukkan bahwa kebijakan investasi di bidang tersebut tidak memberikan pengaruh besar bagi peningkatan maturitas Industri 4.0 secara menyeluruh. Hasil analisis menunjukkan bahwa variabel lean bukan merupakan faktor dominan yang memengaruhi tingkat maturitas Industri 4.0. Terdapat perbedaan pendekatan antara perusahaan dengan maturitas lean rendah dan tinggi, namun tingkat maturitas Industri 4.0 yang dicapai tetap stabil. Hal ini mengindikasikan bahwa meskipun strategi implementasi Industri 4.0 beragam, dampak terhadap tingkat maturitas keseluruhan tidak menunjukkan perbedaan yang berarti. Jadi, faktor lean lebih berperan dalam menentukan strategi implementasi daripada memengaruhi skor maturitas industri 4.0 secara langsung. Hal ini terlihat dari tingkat maturitas keseluruhan yang tetap stabil di berbagai level maturitas lean perusahaan, baik pada kategori rendah maupun tinggi.

3.2. Seleksi Model

Seluruh model yang digunakan mengikuti prosedur standar yang diawali dengan rekayasa fitur melalui seleksi dan pembersihan data. Tahap berikutnya adalah pelatihan model dengan data berlabel untuk mengidentifikasi korelasi antara fitur dan target melalui optimasi fungsi loss. Performa model kemudian diuji menggunakan data validasi untuk penalaan hiperparameter sebelum akhirnya dioperasikan untuk memprediksi tingkat maturitas perusahaan pada dataset baru.

Tabel 2. Perbandingan Performa Statistik Model

Metrik model	Decision Tree (DT)	Random Forest (RF)	Support Vector Machine (SVM)
MSE	0,032	0,037	0,034
MAE	0,063	0,091	0,112
nilai R ²	0,862	0,852	0,864

Dari hasil pengujian pada Tabel 2 menunjukkan bahwa algoritma DT merupakan model yang paling kompetitif dengan capaian MSE 0,032, MAE 0,063, dan skor R² sebesar 0,862. Keunggulan model ini tidak hanya pada akurasi statistiknya, tetapi juga pada aspek transparansi model yang memungkinkan interpretasi logika keputusan secara eksplisit. Berbeda dengan SVM, DT memiliki efisiensi komputasi yang lebih baik dan ketahanan terhadap outliers. Selain itu, kemampuan dalam mengakomodasi interaksi fitur yang kompleks dan hubungan non linear menjadikannya solusi paling ideal. Dengan demikian, DT ditetapkan sebagai model optimal yang membuktikan efektivitasnya dalam aplikasi ML nyata.

Optimasi performa model DT dilakukan melalui pemilihan parameter yang teliti menggunakan metode *grid search*. ditetapkan nilai awal 8 untuk parameter *min samples leaf* untuk memastikan model tetap kokoh, mudah diinterpretasikan, dan memiliki kemampuan generalisasi yang baik. Penentuan batas minimum sampel pada setiap node daun bertujuan agar model mengenali pola dari kelompok data yang lebih representatif, bukan sekadar data tunggal, sehingga wawasan yang dihasilkan lebih kredibel. Melalui evaluasi berbagai kombinasi hiperparameter menggunakan metode *grid search*, konfigurasi optimal yang menghasilkan performa terbaik untuk model DT tercapai pada batas minimum sampel untuk pemisahan node sebesar 8 (*min_samples_split*) dan jumlah minimum sampel pada setiap node daun sebesar 2

(*min_samples_leaf*). Jika dibandingkan dengan Random Forest dan SVM yang terbatas pada analisis deskriptif dan prediktif, DT menawarkan cakupan yang lebih luas melalui analisis deskriptif, prediktif, serta perspektif. Didukung dengan performa yang melampaui model lainnya, DT menjadi solusi optimal untuk kebutuhan analisis penelitian ini.

3.3. Analisis Prediktif

Setelah dilakukan identifikasi terhadap fitur-fitur kunci serta pola korelasi dalam data melalui analisis deskriptif, langkah selanjutnya adalah memanfaatkan fitur tersebut dalam memprediksi tingkat maturitas perusahaan saat ini. Gambar 5 menyajikan model DT di mana setiap simpul mewakili suatu pertanyaan dan setiap cabang merepresentasikan jawaban atas pertanyaan tersebut. Secara konseptual, setiap simpul dipahami sebagai titik keputusan. Melalui proses penelusuran dari akar hingga mencapai simpul terminal (*leaf node*), tingkat maturitas perusahaan dapat diprediksi berdasarkan rangkaian jalur keputusan yang dilalui.

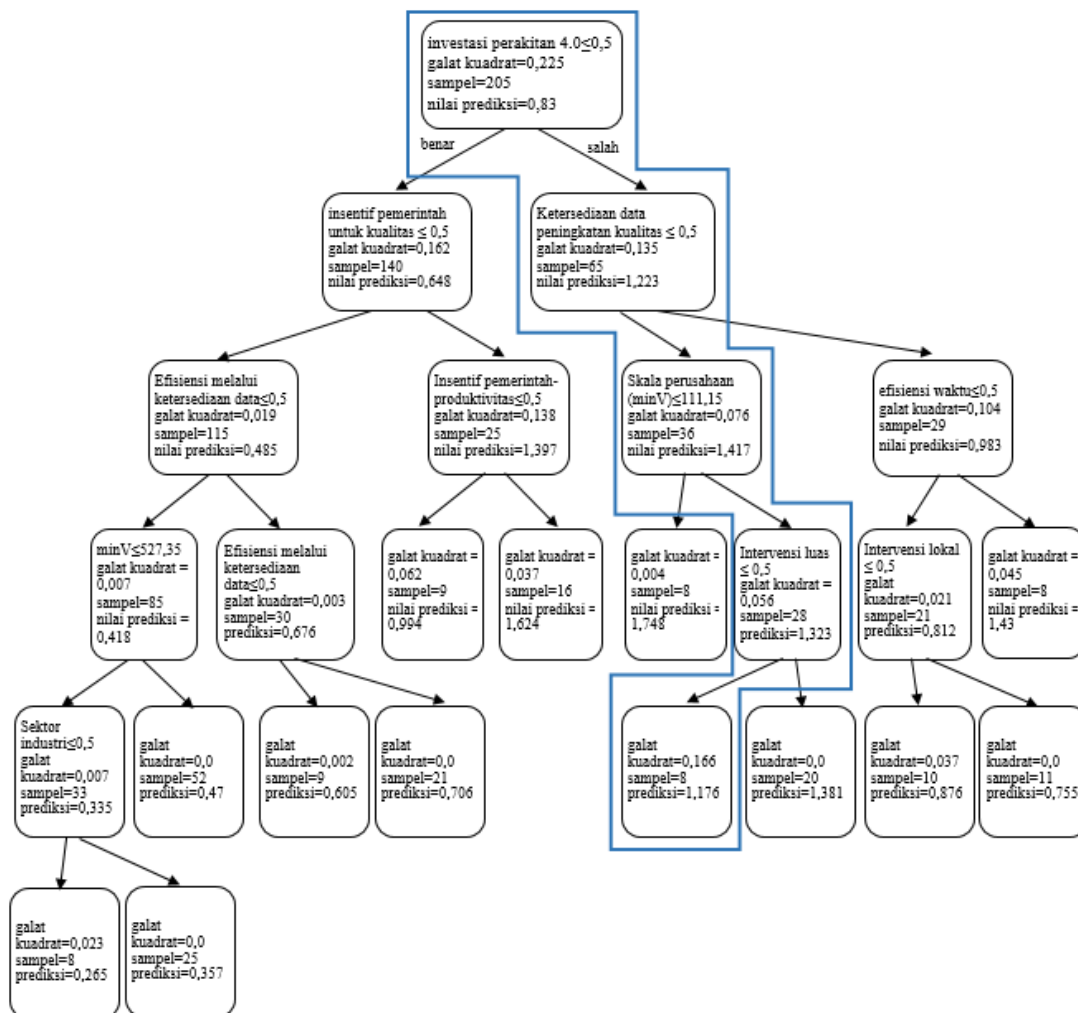
Implementasi model dapat diilustrasikan melalui studi kasus pada garis biru di Gambar 5. Analisis dimulai dari *root node* di mana perusahaan yang memenuhi kriteria simpul pertama berfokus pada investasi perakitan. Pada simpul kedua, jalur diikuti oleh perusahaan yang tidak menargetkan perbaikan kualitas melalui Industri 4.0, tetapi menitikberatkan pada ketersediaan data sebagai driver investasi. Selanjutnya, pada simpul ketiga, dipilih perusahaan dengan skala ukuran di atas 111. Pada simpul keempat, ditemukan bahwa perusahaan tanpa intervensi jangka panjang yang luas cenderung menghasilkan tingkat maturitas Industri 4.0 sebesar 1,177 (simpul kelima/*leaf node*). Melalui penelusuran alur keputusan ini, tingkat maturitas untuk perusahaan dengan karakteristik serupa dapat diprediksi secara akurat pada angka 1,177.

3.4. Analisis perspektif

Fokus penelitian ini adalah meningkatkan level maturitas digital perusahaan. Dengan mengevaluasi simpul-simpul yang ada, kita dapat memetakan langkah-langkah strategis yang secara langsung berdampak pada penguatan maturitas. Penting bagi manajemen untuk memisahkan variabel kontekstual, seperti skala perusahaan dan sektor industri, dari keputusan yang dapat ditindaklanjuti, mengingat variabel kontekstual umumnya bersifat statis. Metodologi ini memungkinkan perusahaan untuk menentukan intervensi spesifik yang diperlukan demi mencapai level maturitas yang lebih tinggi. Dengan demikian, model DT berfungsi sebagai instrumen rekomendasi praktis untuk mendukung upaya perbaikan organisasi yang berkelanjutan. Pada studi kasus perusahaan dengan skor maturitas 1,177, kesamaan parameter pada parent nodes menunjukkan bahwa perusahaan-perusahaan tersebut memiliki profil maturitas yang serupa. Model yang dihasilkan dalam penelitian ini memberikan rekomendasi bagi kelompok perusahaan ini untuk menerapkan intervensi luas secara berkelanjutan guna mengelevasi level maturitas digital mereka. Justifikasi atas rekomendasi ini selaras dengan temuan (Rossini et al., 2022), di mana strategi intervensi substansial menjadi syarat mutlak bagi perusahaan dengan tingkat maturitas lean rendah untuk mencapai kemajuan yang berarti.

Melalui strategi yang diusulkan, perusahaan diproyeksikan dapat meningkatkan level maturitas dari 1,177 menjadi 1,382. Data menunjukkan kontras yang signifikan: perusahaan tanpa intervensi lokal memiliki tingkat maturitas hanya 0,754, sedangkan yang menerapkannya mencapai nilai 0,877. Angka ini membuktikan efektivitas intervensi lokal sebagai pendorong maturitas organisasi. Hubungan ini diperkuat oleh temuan, yang mengaitkan intervensi lokal dengan maturitas lean yang tinggi. Oleh karena itu, pengintegrasian aspek intervensi lokal ke dalam strategi perusahaan berperan ganda; yakni mempercepat pencapaian Industri 4.0 sekaligus memperkuat budaya *lean thinking*. Strategi komprehensif ini esensial bagi perusahaan untuk memosisikan diri secara strategis dalam ekosistem Industri 4.0 yang terus bertransformasi. Perusahaan-perusahaan tersebut memiliki pilihan untuk menempuh jalur kedua, yakni Efisiensi Waktu-Perbaikan Deteksi Pemborosan, yang secara signifikan mampu meningkatkan level maturitas keseluruhan dari 0,754 menjadi 1,42. Temuan ini menegaskan bahwa efisiensi waktu dalam mendeteksi pemborosan merupakan faktor penentu dalam eskalasi maturitas Industri 4.0. Hal ini menyiratkan bahwa pengalokasian sumber daya dan upaya strategis untuk mengoptimalkan proses deteksi pemborosan sangatlah vital bagi transformasi digital. Hubungan antara peningkatan kinerja berbasis waktu dan efektivitas deteksi pemborosan ini memiliki korelasi yang sangat kuat dengan prinsip-prinsip lean. Deteksi dan pengurangan pemborosan adalah pilar utama dalam metodologi lean untuk mencapai efisiensi maksimal dengan sumber daya minimal. Menjadikan perbaikan deteksi pemborosan

sebagai penggerak investasi Industri 4.0 memungkinkan organisasi menerapkan prinsip lean dalam mengeliminasi aktivitas tanpa nilai tambah. Indikator efisiensi waktu, peningkatan deteksi pemborosan mencerminkan krusialnya efisiensi waktu dalam strategi deteksi pemborosan. Dengan adanya penghapusan pemborosan, prinsip lean memfasilitasi penyederhanaan proses dan reduksi *lead times*, sehingga mendorong peningkatan kinerja operasional yang menyeluruh.



Gambar 5. Model *Decision Tree* untuk Prediksi Maturitas Industri 4.0

4. KESIMPULAN

Penelitian ini berhasil memetakan faktor-faktor penentu tingkat kematangan Industri 4.0 dan menguji pengaruh kematangan Lean terhadap transformasi digital tersebut. Berbeda dengan penelitian terdahulu yang umumnya mengevaluasi model kematangan secara konvensional, kontribusi ilmiah (*novelty*) penelitian ini terletak pada integrasi model interdisipliner Digital Lean melalui algoritma DT untuk memproyeksikan estimasi peningkatan skor kematangan digital secara transparan melalui jalur intervensi yang terarah.

Berdasarkan hasil analisis kuantitatif, pengintegrasian aspek intervensi lokal ke dalam strategi perusahaan terbukti memberikan dampak ganda yang signifikan. Data menunjukkan kontras yang nyata di mana perusahaan tanpa intervensi lokal hanya memiliki tingkat maturitas sebesar 0,754, sedangkan perusahaan yang menerapkannya berhasil mencapai nilai 0,877. Hubungan ini memperkuat temuan bahwa intervensi lokal berkorelasi langsung dengan tingginya maturitas lean. Melalui strategi optimasi jalur keputusan yang diusulkan, perusahaan diproyeksikan mampu mendongkrak level maturitas keseluruhan dari 1,177 menjadi 1,382. Selain itu, model DT mengidentifikasi jalur alternatif kedua bagi

perusahaan, yaitu melalui jalur Efisiensi Waktu Perbaikan Deteksi Pemborosan, yang secara signifikan mampu melipatgandakan level maturitas dari 0,754 menjadi 1,42. Angka-angka empiris ini membuktikan keandalan model DT dalam menghasilkan rekomendasi perbaikan yang konkret dan aplikatif berdasarkan klaster karakteristik perusahaan.

Secara teoritis, penelitian ini memperkaya literatur manajemen operasi dengan menyediakan bukti kuantitatif mengenai titik temu (*intersection*) antara budaya lean thinking tradisional dan adopsi teknologi Industri 4.0. Secara praktis, jalur-jalur keputusan yang dihasilkan oleh model DT berfungsi sebagai instrumen panduan strategis bagi para pengambil kebijakan di industri untuk memosisikan diri secara tepat dan memilih rute investasi digital yang paling efisien dalam ekosistem Industri 4.0 yang dinamis.

5. REFERENSI

- Angreani, L. S., Vijaya, A., & Wicaksono, H. (2024). Enhancing strategy for Industry maturity models and standard reference architectures alignment. *Journal of Manufacturing Technology Management*, 35(4), 848–873. <https://doi.org/10.1108/JMTM-07-2022-0269>
- Bhadu, J., Bhamu, J., & Saraswat, P. (2023). An Analytic Hierarchy Process (AHP) Approach for Prioritizing the Industries 4.0 Technologies (I4.0T). *EVERGREEN*, 10(2), 667–675. <https://doi.org/https://doi.org/10.5109/6792813>
- Castagnoli, R., Büchi, G., & Cugno, M. (2022). Evolution of industry 4 . 0 and international business : A systematic literature review and a research agenda. *European Management Journal*, 40(September 2021), 572–589. <https://doi.org/10.1016/j.emj.2021.09.002>
- Chen, T., Sampath, V., May, M. C., Shan, S., Jorg, O. J., José, J., Martín, A., Stamer, F., Fantoni, G., Tosello, G., & Calaon, M. (2023). Machine Learning in Manufacturing towards Industry 4 . 0 : From ' For Now ' to ' Four-Know ' . *Applied Sciences*, 13(1903), 1–32. <https://doi.org/https://doi.org/10.3390/app13031903>
- Costa, F., Alesman, N., Bilancia, A., Luz, G., & Portioli, A. (2025). Integrating industry 4 . 0 and lean manufacturing for a sustainable green transition : A comprehensive model. *Journal of Cleaner Production*, 465(May 2024), 142728. <https://doi.org/10.1016/j.jclepro.2024.142728>
- Elnadi, M., & Omar, Y. (2022). Industry 4.0: critical investigations and synthesis of key findings. *Management Review Quarterly*, 74(0123456789), 711–744. <https://doi.org/10.1007/s11301-022-00314-4>
- Hernandez, M., Epelde, G., Alberdi, A., Cilla, R., & Rankin, D. (2023). Standardised Metrics and Methods for Synthetic Tabular Data Evaluation. *TechRxiv*, 21(September), 1–36. <https://doi.org/10.36227/techrxiv.16610896.v1>
- Jamari, S., & Fedouaki, F. (2025). Industry 4 . 0 Enablers and Lean Manufacturing Tools in Respect of Human Resources. *The 1st International Conference on Smart Management in Industrial and Logistics Engineering (SMILE 2025)*, 1–7. <https://doi.org/https://doi.org/10.3390/engproc2025097043>
- Jamwal, A., Mahato, S., Agrawal, R., & Sharma, M. (2025). Are mature firms more sustainable? An analysis of Industry 4.0 maturity. *International Journal of Innovation Studies*, 1–43. <https://doi.org/10.1016/j.ijis.2025.12.005>
- Jaskó, S. (2025). The Future of Manufacturing and Industry 4 . 0. *Applied Sciences*, 15(9), 1–8. <https://doi.org/https://doi.org/10.3390/app15094655>
- Komkowski, T., Antony, J., Garza-reyes, J. A., Luz, G., Pongboonchai-empl, T., Komkowski, T., Antony, J., Garza-reyes, J. A., & Luz, G. (2023). The integration of Industry 4 . 0 and Lean Management : a systematic review and constituting elements perspective. *Total Quality Management & Business Excellence*, 3363(34), 1052–1069. <https://doi.org/10.1080/14783363.2022.2141107>
- Krissensen, I. E., & Amrina, U. (2025). Integrasi Lean dan Green Manufacturing di Sektor Industri : Systematic Literature Review. *Proceeding Mercu Buana Conference on Industrial Engineering*, 7(July), 1–12. <https://doi.org/http://dx.doi.org/10.22441/MBCIE.2025.34314>
- Maware, C., & li, D. M. P. (2023). Can Industry 4 . 0 Assist Lean Manufacturing in Attaining Sustainability over Time ? Evidence from the US Organizations. *Sustainability*, 15(3), 1–23. <https://doi.org/https://doi.org/10.3390/su15031962>
- Pangestu, N. A. P., Parung, J., & Wibisono, E. (2024). PENERAPAN TEKNOLOGI INDUSTRI 4.0 DALAM LEAN WAREHOUSING: LITERATURE REVIEW. *Jurnal Ilmiah Teknik Industri*, 12(2), 79–90.

- <https://doi.org/https://doi.org/10.24912/jitiuntar.v12i2.31009>
- Purnama, D. A., & Cahyo, W. N. (2025). A machine learning-driven Six Sigma framework for enhancing the quality improvement and productivity in the Aircraft Manufacturing. *OPSI*, 18(1), 136–151. <https://doi.org/https://doi.org/10.31315/opsi.v18i1.13960>
- Rahardjo, B., Wang, F., Yeh, R., & Chen, Y. (2023). Lean Manufacturing in Industry 4.0: A Smart and Sustainable Manufacturing System. *Machines*, 11(1), 1–17. <https://doi.org/https://doi.org/10.3390/machines11010072>
- Rossini, M., Cifone, F. D., Kassem, B., Costa, F., & Portioli-staudacher, A. (2022). Being lean : how to shape digital transformation in the manufacturing sector. *Journal of Manufacturing Technology Management*, 32(9), 239–259. <https://doi.org/10.1108/JMTM-12-2020-0467>
- Solikhah, E. W., Asih, H. M., Astuti, F. H., & Ghazali, I. (2024). Industry 4.0 Readiness Trends: A Bibliometric and Visualization Analysis. *International Journal of Robotics and Control Systems*, 4(1), 105–124. <https://doi.org/doi.org/10.31763/ijrcs.v4i1.1247>
- Surindra, M. D., Caesarendra, W., Królczyk, G., & Gupta, M. K. (2024). Challenges of implementing Industry 4.0 in developed and developing countries : A comparative review. *Mechanical Engineering for Society and Industry*, 4(3), 455–489. <https://doi.org/https://doi.org/10.31603/mesi.12177>
- Tashkinov, A. G. (2025). The application of industry 4 . 0 into the company ' s production activities through effective decision-making. *Scientific Reports*, 15(34202), 1–11. <https://doi.org/https://doi.org/10.1038/s41598-025-15688-0>
- Treviño-elizondo, B. L., & Garc, H. (2023). A Maturity Model to Become a Smart Organization Based on Lean and Industry 4 . 0 Synergy. *Sustainability*, 15(17), 1–24. <https://doi.org/https://doi.org/10.3390/su151713151>
- Yang, X., Fu, L., Zhu, L., & Lv, J. (2025). Recent Advances in Lean Techniques for Discrete Manufacturing Companies : A Comprehensive Review. *Machines*, 13(4), 1–34. <https://doi.org/https://doi.org/10.3390/machines13040280>