



Implementation of Decision Tree Classification Model for Organizational Performance Evaluation and Decision Support

Implementasi Model Klasifikasi *Decision Tree* untuk Evaluasi Kinerja Organisasi dan Dukungan Pengambilan Keputusan

**Tamara Juliyanti^{1*}, Xenia Clarissa Valencia Marpaung², Nanda Salsabila Az-Zahra³,
Silvia Nabilaputri⁴, Allsela Meiriza⁵, Ken Ditha Tania⁶, Ahmad Rifai⁷**

^{1,2,3,4,5,6,7}Program Studi Sistem Informasi, Fakultas Ilmu Komputer,
Universitas Sriwijaya, Indonesia

E-Mail: ¹09031182328010@student.unsri.ac.id, ²09031182328017@student.unsri.ac.id,
³09031182328016@student.unsri.ac.id, ⁴09031182328014@student.unsri.ac.id, ⁵allsela@unsri.ac.id,
⁶kenya.tania@gmail.com, ⁷ahmadrifai@ilkom.unsri.ac.id

Received Feb 14th 2026; Revised Mar 14th 2026; Accepted Apr 18th 2026; Available Online Apr 28th 2026

Corresponding Author: Tamara Juliyanti

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Unintegrated performance data management limits the optimal use of organizational information in strategic decision-making. This study aims to develop a data-driven knowledge management model by integrating the SECI Model and the Decision Tree algorithm at PT PLN (Persero) UID Jawa Barat. Operational performance data were processed through data cleaning, attribute selection, and data transformation stages, and analyzed using the C4.5 algorithm in RapidMiner to generate classification models and decision rules. The results show that the proposed model achieved an accuracy of 95.62% with a standard deviation of $\pm 6.18\%$. Furthermore, the model produces interpretable decision rules and identifies dominant factors influencing operational unit performance. These rules are mapped into the SECI stages to generate documented explicit knowledge. The integration of data mining and knowledge management provides a systematic approach to support organizational performance evaluation and data-driven decision-making.

Keywords: Data Mining, Decision Tree, Knowledge Management, Organizational Performance, SECI Model

Abstrak

Pengelolaan data kinerja yang tidak terintegrasi menyebabkan informasi organisasi belum dimanfaatkan secara optimal dalam pengambilan keputusan strategis. Penelitian ini bertujuan mengembangkan model manajemen pengetahuan berbasis data dengan mengintegrasikan Model SECI dan algoritma *Decision Tree* pada PT PLN (Persero) UID Jawa Barat. Data kinerja operasional diolah melalui tahapan pembersihan data, seleksi atribut, dan transformasi data, kemudian dianalisis menggunakan algoritma C4.5 pada RapidMiner untuk menghasilkan model klasifikasi dan aturan keputusan. Hasil penelitian menunjukkan bahwa model yang diusulkan mampu mencapai akurasi sebesar 95,62% dengan standar deviasi $\pm 6,18\%$. Selain itu, model menghasilkan aturan keputusan yang mudah diinterpretasikan serta mampu mengidentifikasi faktor dominan yang memengaruhi kinerja unit operasional. Aturan tersebut dipetakan ke dalam tahapan SECI untuk menghasilkan pengetahuan eksplisit yang terdokumentasi. Integrasi *data mining* dan manajemen pengetahuan memberikan pendekatan yang sistematis dalam mendukung evaluasi kinerja organisasi dan pengambilan keputusan berbasis data.

Kata Kunci: Data Mining, Decision Tree, Kinerja Organisasi, Manajemen Pengetahuan, Model SECI

1. PENDAHULUAN

Organisasi modern menghadapi kompleksitas yang semakin tinggi akibat pertumbuhan volume data operasional dan tuntutan peningkatan kinerja secara berkelanjutan. Data kinerja unit operasional sejatinya merupakan aset strategis yang dapat mendukung evaluasi serta pengambilan keputusan. Namun demikian, dalam praktiknya data tersebut kerap hanya dimanfaatkan sebagai laporan administratif rutin dan belum diolah menjadi pengetahuan yang bernilai. Situasi ini menunjukkan bahwa pemanfaatan data kinerja sebagai dasar pembelajaran organisasi dan keputusan strategis masih belum optimal.

Implementasi sistem manajemen pengetahuan yang efektif terbukti mampu mentransformasikan data dan informasi menjadi pengetahuan strategis yang mendukung peningkatan efektivitas, efisiensi, serta kualitas pengambilan keputusan organisasi [1]. Selain itu, pendekatan manajemen pengetahuan yang terintegrasi dengan analitik data terbukti mampu meningkatkan kinerja organisasi melalui optimalisasi proses penciptaan, berbagi, dan penerapan pengetahuan dalam pengambilan keputusan strategis [2]. Temuan tersebut mengindikasikan bahwa integrasi manajemen pengetahuan dan analitik data telah menjadi fokus pengembangan dalam berbagai penelitian sebelumnya.

Sejalan dengan itu, penelitian sebelumnya menegaskan bahwa ketersediaan data operasional dalam organisasi tidak secara otomatis menghasilkan keputusan yang berkualitas tanpa dukungan proses analitik yang terstruktur dan terintegrasi [3]. Volume data yang besar menuntut pengelolaan yang mencakup *data management*, *data analytics*, dan *business intelligence* agar data mentah dapat dikonversi menjadi informasi dan pengetahuan yang bernilai. Integrasi ketiga aspek tersebut memungkinkan organisasi memperoleh *insight* yang relevan sebagai landasan pengambilan keputusan yang lebih objektif dan terarah.

Penelitian terbaru menunjukkan bahwa pemanfaatan *big data analytics* yang terintegrasi dengan *knowledge management* secara signifikan meningkatkan kualitas pengambilan keputusan dan kinerja organisasi [4]. Selain itu, studi lain mengungkapkan bahwa penerapan *data analytics* dalam organisasi modern mampu meningkatkan efektivitas pengambilan keputusan berbasis data, terutama dalam lingkungan yang dinamis dan kompleks [5]. Temuan ini menegaskan bahwa integrasi analitik data dan manajemen pengetahuan menjadi faktor kunci dalam menghasilkan keputusan yang lebih akurat dan berbasis data, sehingga penelitian ini relevan untuk dilakukan.

Lebih jauh, analitik data tidak hanya berfungsi sebagai perangkat teknis dalam pengolahan data, tetapi juga memiliki peran strategis dalam mendukung evaluasi kinerja dan formulasi kebijakan organisasi. Meskipun demikian, kajian yang secara langsung mengaitkan pemanfaatan analitik data dengan proses pembentukan pengetahuan organisasi, khususnya melalui metode klasifikasi yang mudah dipahami, masih relatif terbatas. Hal ini menunjukkan adanya celah penelitian dalam pengembangan model analitik yang tidak hanya menghasilkan klasifikasi kinerja, tetapi juga mendukung pembentukan pengetahuan organisasi secara sistematis dan berkelanjutan [3].

Dalam penerapan metode klasifikasi, algoritma *Decision Tree* banyak digunakan karena menghasilkan model yang transparan dan mudah diinterpretasikan. Studi perbandingan beberapa algoritma klasifikasi menunjukkan bahwa *Decision Tree* memiliki performa yang kompetitif dibandingkan metode lain seperti *Naïve Bayes* dan *K-NN* serta mampu memberikan akurasi yang tinggi dalam proses klasifikasi data [6]. Temuan ini menegaskan relevansi *Decision Tree* dalam analisis data organisasi yang membutuhkan model yang mudah dipahami oleh pengambil keputusan.

Selain itu, penerapan *Decision Tree* juga terbukti efektif dalam konteks prediksi dan evaluasi berbasis data, seperti pada studi prediksi penipuan transaksi keuangan yang mengkombinasikan teknik *supervised learning* dan *resampling* untuk meningkatkan performa klasifikasi [7]. Hasil penelitian tersebut menunjukkan bahwa *Decision Tree* mampu menghasilkan tingkat akurasi yang tinggi dan stabil, terutama dalam menangani data yang tidak seimbang. Hal ini memperkuat posisi *Decision Tree* sebagai metode yang adaptif dan aplikatif dalam berbagai kebutuhan analisis kinerja organisasi.

Kondisi serupa terjadi pada pengelolaan data kinerja unit operasional di PT PLN (Persero) UID Jawa Barat, dimana data tersedia secara periodik namun belum dimanfaatkan secara optimal untuk menghasilkan pengetahuan yang mendukung pembelajaran organisasi. Penelitian terdahulu umumnya berfokus pada *data analytics* atau algoritma klasifikasi untuk prediksi kinerja, serta kajian *knowledge management* yang bersifat konseptual, sehingga integrasi keduanya masih terbatas. Oleh karena itu, penelitian ini mengintegrasikan Model SECI dan algoritma *Decision Tree* untuk membentuk *knowledge* organisasi berbasis data, dimana hasil klasifikasi tidak hanya menjadi output analitik, tetapi juga dikonversi menjadi pengetahuan eksplisit yang dapat dimanfaatkan dalam evaluasi dan pengambilan keputusan.

2. METODE PENELITIAN

2.1 Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain studi kasus pada PT PLN (Persero) UID Jawa Barat. Pendekatan ini dipilih karena penelitian berfokus pada pengolahan data kinerja unit operasional untuk membangun model *knowledge management* berbasis analisis data. Studi kasus memungkinkan analisis dilakukan secara mendalam terhadap konteks organisasi tertentu dengan memanfaatkan data operasional aktual. Metode yang digunakan mengintegrasikan algoritma klasifikasi *Decision Tree* dengan kerangka SECI Model untuk membentuk *knowledge* organisasi berbasis data. Pendekatan integratif ini didasarkan pada temuan bahwa kombinasi *data analytics* dan *knowledge management* mampu meningkatkan kualitas pengambilan keputusan organisasi [4], [5], [8].

2.2 Teknik Pengumpulan Data

Data diperoleh melalui metode dokumentasi dengan mengakses laporan kinerja periodik unit

operasional yang tersedia dalam sistem pelaporan internal organisasi. Data yang dikumpulkan mencakup indikator capaian kinerja, nilai realisasi, dan kategori evaluasi unit kerja. Pendekatan dokumentasi dipilih karena memungkinkan penggunaan data yang telah terstandarisasi dan terdokumentasi secara sistematis. Pemanfaatan data operasional sebagai sumber analitik dinilai strategis dalam mendukung *evidence-based decision making* [9]. Integrasi data organisasi dengan proses *knowledge management* juga terbukti meningkatkan kualitas pengelolaan pengetahuan [8]. *Dataset* yang diperoleh selanjutnya diposisikan sebagai sumber *knowledge* potensial yang akan diolah melalui teknik klasifikasi dan dikonversi menjadi pengetahuan eksplisit [8].

2.3 Tahap Pra Proses Data

Tahap praproses dilakukan untuk memastikan kualitas dan konsistensi data sebelum proses pemodelan dilakukan. Pada tahap ini, data dibersihkan dengan menghapus duplikasi, menangani *missing value*, serta menyesuaikan format numerik agar sesuai dengan kebutuhan analisis. Selanjutnya dilakukan transformasi data, termasuk konversi nilai persentase ke dalam format numerik serta penyederhanaan kategori kinerja agar dapat diproses dalam algoritma klasifikasi. Tahap berikutnya adalah seleksi atribut, yaitu memilih variabel yang paling relevan terhadap variabel target klasifikasi guna meningkatkan efektivitas dan akurasi model. Kualitas hasil analitik sangat dipengaruhi oleh kesiapan data, sehingga praproses menjadi tahapan fundamental dalam ekstraksi *knowledge* berbasis data [10].

2.4 Pembangunan Decision Tree

Algoritma *Decision Tree* diterapkan sebagai metode klasifikasi untuk mengenali pola kinerja pada unit operasional. Pendekatan klasifikasi ini dipilih karena mampu menghasilkan aturan keputusan yang jelas, transparan, dan mudah dipahami oleh pengguna [11]. Secara mekanisme, metode ini membagi *dataset* ke dalam beberapa cabang berdasarkan atribut yang paling berpengaruh terhadap hasil klasifikasi, sehingga terbentuk struktur pohon keputusan yang dapat menggambarkan proses pengambilan keputusan secara terstruktur dan sistematis [12].

Pemilihan atribut terbaik dalam pembentukan pohon keputusan dilakukan menggunakan konsep *Entropy* dan *Information Gain*. *Entropy* digunakan untuk mengukur tingkat ketidakpastian atau heterogenitas data dalam suatu *dataset*, yang dihitung menggunakan Persamaan 1.

$$Entropy(S) = - \sum_{i=1}^n p_i \log_2(p_i) \quad (1)$$

Dengan P_i adalah proporsi jumlah data pada kelas ke- i terhadap total data dalam *dataset* S berdasarkan n yang merupakan jumlah kelas dalam *dataset*. Untuk menentukan atribut terbaik sebagai node dalam pohon keputusan, digunakan perhitungan *Information Gain*, yang dapat dilihat pada Persamaan 2.

$$Gain(S, A) = Entropy(S) - \sum_{v \in values(A)} \frac{|S_v|}{|S|} \cdot Entropy(S_v) \quad (2)$$

Dengan $Gain(S, A)$ adalah pengukuran besarnya pengurangan *Entropy* setelah *dataset* S dipartisi menjadi S_v dan S_v adalah subset data yang terbentuk berdasarkan atribut A . $|S_v|$ menyatakan jumlah data pada subset ke- i dan $|S|$ adalah jumlah total data dalam *dataset* awal. Pemilihan atribut dalam *Decision Tree* dilakukan secara rekursif hingga terbentuk cabang dengan kelas yang homogen atau telah memenuhi kriteria penghentian tertentu. Tahapan ini menghasilkan aturan berbentuk *IF-THEN* yang sederhana dan mudah dipahami oleh pihak manajemen. Sejumlah penelitian terdahulu menunjukkan bahwa algoritma *Decision Tree* mampu membangun model klasifikasi yang efektif dengan tingkat akurasi tinggi dalam berbagai konteks analisis data, seperti analisis kualitas udara [13], klasifikasi status kemiskinan berbasis data sosial ekonomi [14], serta prediksi kelulusan mahasiswa menggunakan data akademik [15].

Selain itu, penerapan *Decision Tree* pada analisis data akademik terbukti mampu mengungkap pola-pola penting yang memengaruhi hasil klasifikasi sekaligus mendukung pengambilan keputusan berbasis data [16]. Integrasi teknik analitik dengan sistem informasi organisasi juga terbukti meningkatkan kualitas keputusan melalui pemanfaatan pola data yang terstruktur [8] dan menjadi semakin optimal ketika diperkuat dengan praktik *knowledge management* [4], [5]. Dengan demikian, dalam penelitian ini algoritma *Decision Tree* tidak hanya dimanfaatkan sebagai alat klasifikasi, tetapi juga sebagai sarana pembentukan *knowledge* eksplisit guna mendukung pengambilan keputusan terkait kinerja organisasi.

2.5 Implementasi RapidMiner

Implementasi model dilakukan menggunakan perangkat lunak RapidMiner untuk memastikan proses analitik dilakukan secara sistematis dan terdokumentasi. Penggunaan platform analitik berbasis teknologi informasi mendukung integrasi antara pengolahan data dan pengelolaan pengetahuan organisasi. Studi pemetaan sistematis menunjukkan bahwa integrasi *knowledge management* dengan teknologi informasi dan

analitik data mampu memperkuat kapabilitas organisasi dalam pengambilan keputusan berbasis sistem [8].

Dalam berbagai studi *data mining*, RapidMiner kerap digunakan sebagai perangkat pendukung untuk mengimplementasikan algoritma klasifikasi seperti *Decision Tree*, karena kemampuannya dalam memvisualisasikan alur pemodelan dan menyederhanakan analisis pola data yang kompleks. Penelitian terdahulu menunjukkan bahwa pemanfaatan RapidMiner dapat meningkatkan efisiensi proses pemodelan data serta menghasilkan model prediksi yang lebih mudah dipahami oleh pengguna non-teknis [13]. Selain itu, RapidMiner mendukung pelaksanaan proses klasifikasi secara terstruktur, dimulai dari tahap *data preprocessing*, pembangunan model, hingga evaluasi kinerja model melalui metrik seperti akurasi dan *confusion matrix*.

Pemanfaatan RapidMiner dalam penelitian klasifikasi berbasis *Decision Tree* telah diaplikasikan pada berbagai kajian, salah satunya dalam klasifikasi status kemiskinan masyarakat berdasarkan data sosial ekonomi. Temuan penelitian tersebut menunjukkan bahwa RapidMiner mampu menghasilkan model klasifikasi dengan akurasi tinggi serta membantu mengidentifikasi atribut yang paling berpengaruh dalam proses pengambilan keputusan berbasis data [14]. Selain itu, studi lain yang menerapkan RapidMiner untuk memprediksi kelulusan mahasiswa juga membuktikan bahwa platform ini efektif dalam membangun model prediksi yang andal sekaligus mendukung analisis faktor-faktor yang memengaruhi hasil klasifikasi [15].

Pemanfaatan *big data analytics* dalam konteks manajemen pengetahuan terbukti meningkatkan efektivitas pengambilan keputusan melalui penyediaan insight yang lebih komprehensif [5]. Oleh karena itu, penggunaan RapidMiner dalam penelitian ini menjadi bagian dari pendekatan analitik yang terstruktur dan berbasis teknologi.

2.6 Integrasi SECI Model dan Pembentukan Knowledge

Model SECI tetap menjadi kerangka kerja sentral dalam kajian *knowledge management* modern karena menjelaskan proses penciptaan pengetahuan organisasi melalui empat tahapan (*socialization*, *externalization*, *combination*, dan *internalization*) yang menekankan konversi berkelanjutan antara *tacit* dan *explicit knowledge* sebagai basis pembelajaran organisasi [17].

Proses pembentukan *knowledge* organisasi dilakukan dengan mengintegrasikan hasil klasifikasi ke dalam kerangka SECI Model. Aturan *IF-THEN* yang dihasilkan dari analisis *Decision Tree* ditransformasikan menjadi *knowledge* eksplisit yang terdokumentasi dan dapat dimanfaatkan dalam evaluasi kinerja. Pemilihan model SECI didasarkan pada kemampuannya dalam menjelaskan konversi pengetahuan antara *tacit knowledge* dan *explicit knowledge* melalui empat tahapan utama, yaitu *socialization*, *externalization*, *combination*, dan *internalization* [18]. Tahapan SECI Model dapat dilihat pada Gambar 1.

Dalam pengelolaan pengetahuan organisasi, model SECI memungkinkan pengalaman, informasi, serta hasil analisis data yang sebelumnya bersifat implisit diubah menjadi pengetahuan terstruktur yang dapat dibagikan secara luas di lingkungan organisasi. Penelitian sebelumnya menunjukkan bahwa model SECI efektif diterapkan dalam sistem manajemen pengetahuan untuk mengonversi pengetahuan *tacit* menjadi pengetahuan eksplisit yang terdokumentasi dalam sistem informasi sehingga dapat diakses dan dimanfaatkan oleh berbagai pihak dalam organisasi [19].

Selain itu, kemajuan teknologi digital turut memperkuat proses penciptaan pengetahuan dalam organisasi. Transformasi digital terbukti mendukung penciptaan dan transfer pengetahuan melalui integrasi teknologi informasi dengan proses manajemen pengetahuan, sehingga mendorong inovasi serta peningkatan kinerja organisasi [20]. Literatur terbaru juga menunjukkan bahwa *big data analytics* akan memberikan dampak yang lebih optimal terhadap kinerja organisasi apabila didukung oleh praktik *knowledge management* yang efektif [4]. Tahapan SECI Model dapat dilihat pada Gambar 1.


Berdasarkan Gambar 1 tahapan SECI, dalam penelitian ini manajemen pengetahuan berperan sebagai mediator yang mentransformasikan hasil analitik menjadi dasar pengambilan keputusan strategis. Dengan demikian, integrasi analitik data dan pengelolaan pengetahuan dalam penelitian ini tidak hanya bersifat teknis, tetapi juga strategis dalam membangun sistem pengambilan keputusan berbasis *knowledge*.

2.7 Alur Proses Penelitian


Peneliti membuat alur proses penelitian yang dapat dilihat pada Gambar 2 untuk memastikan penelitian berjalan secara sistematis dan terstruktur, disusun suatu alur proses penelitian yang menggambarkan tahapan sejak identifikasi permasalahan hingga terbentuknya *knowledge* organisasi berbasis data. Alur ini dirancang agar setiap tahapan saling terintegrasi, mulai dari pengumpulan dan pengolahan data kinerja hingga konversi hasil analitik menjadi *knowledge* eksplisit yang dapat dimanfaatkan dalam pengambilan keputusan. Diagram alur penelitian berikut menunjukkan tahapan proses yang dilakukan secara berurutan dan logis. Alur proses yang dilakukan dalam penelitian ini terpetakan pada Gambar 2.

Pada Gambar 2 terdapat beberapa tahap alur proses penelitian. Tahap pertama adalah identifikasi masalah, yaitu menganalisis kondisi pemanfaatan data kinerja yang belum terintegrasi dengan manajemen pengetahuan. Tahap kedua merupakan pengumpulan data melalui dokumentasi laporan kinerja periodik unit operasional. Selanjutnya dilakukan pra-proses data yang meliputi pembersihan data, transformasi atribut, dan

seleksi variabel yang relevan. Tahap berikutnya adalah pembangunan model *Decision Tree* untuk mengklasifikasikan data dan mengidentifikasi pola kinerja.



Gambar 1. Tahapan SECI Model



Gambar 2. Alur Proses Penelitian

Model yang terbentuk kemudian dievaluasi dan diekstraksi menjadi aturan keputusan (*decision rules*) dalam bentuk *IF-THEN*. Aturan tersebut selanjutnya diintegrasikan ke dalam kerangka SECI Model untuk mengonversi hasil analitik menjadi *knowledge* eksplisit. Tahap akhir adalah pembentukan *knowledge* organisasi, yaitu mendokumentasikan dan mendistribusikan *knowledge* yang dihasilkan agar dapat digunakan dalam proses evaluasi serta pengambilan keputusan kinerja secara sistematis.

3. HASIL DAN PEMBAHASAN

3.1 Tahap Sosialisasi (*Tacit to Tacit*)

Tahap *socialization* menghasilkan identifikasi *tacit knowledge* yang diperoleh melalui diskusi, wawancara, dan forum evaluasi kinerja yang melibatkan pimpinan unit serta manajer operasional. Hasilnya

menunjukkan bahwa faktor seperti produktivitas, efisiensi waktu, pencapaian target strategis, serta kombinasi beberapa indikator menjadi pertimbangan utama dalam menentukan kategori kinerja unit.

Dalam penelitian ini, *tacit knowledge* berasal dari pengalaman, intuisi, dan pemahaman manajerial yang belum terdokumentasi secara formal. Informasi tersebut mencakup persepsi terhadap faktor penentu kinerja, pengalaman dalam pencapaian target, serta standar internal dalam menetapkan klasifikasi kinerja. Temuan ini menunjukkan bahwa organisasi telah memiliki dasar penilaian kinerja berbasis pengalaman manajerial, namun masih bersifat implisit dan belum terdokumentasi secara sistematis. Oleh karena itu, pengetahuan tersebut perlu dikonversi menjadi bentuk yang lebih terstruktur untuk mendukung analisis dan pengambilan keputusan berbasis data. Tabel 1 adalah data tasit yang menjadi dasar penyusunan *dataset* penelitian.

Tabel 1. Identifikasi Data Tasit

Bentuk <i>Tacit Knowledge</i>	Sumber Pengetahuan	Deskripsi
Persepsi bahwa produktivitas berpengaruh terhadap kinerja	Pimpinan Unit	Keyakinan bahwa unit dengan <i>output</i> tinggi cenderung memiliki kategori kinerja lebih baik
Efisiensi waktu menentukan capaian target	Manajer Operasional	Pengalaman bahwa keterlambatan proses menurunkan performa unit
Kombinasi beberapa indikator menentukan kategori kinerja	Forum Evaluasi	Standar internal dalam menentukan kategori “Tinggi”, “Sedang”, atau “Rendah”
Target strategis menjadi tolak ukur utama	Rapat Perencanaan	Pemahaman bahwa capaian target merupakan indikator keberhasilan utama

Berdasarkan pengetahuan tasit yang telah diidentifikasi pada Tabel 1, struktur *dataset* penelitian disusun menggunakan variabel kinerja yang meliputi target, realisasi, dan capaian. Variabel target merepresentasikan perencanaan strategis organisasi, sedangkan realisasi menunjukkan hasil kinerja aktual yang dicapai oleh unit operasional. Sementara itu, capaian digunakan sebagai indikator efektivitas pelaksanaan kinerja sekaligus dasar dalam pembentukan kategori klasifikasi. Pada tahap implementasi algoritma C4.5, dilakukan transformasi data melalui pembentukan variabel agregat tahunan serta penetapan kategori kinerja sebagai label klasifikasi. Dengan struktur data tersebut, model *Decision Tree* dapat mengidentifikasi atribut yang paling berpengaruh terhadap capaian kinerja unit.

3.2 Tahap Eksternalisasi (*Tacit to Explicit*)

Tahap eksternalisasi merupakan proses konversi *tacit knowledge* menjadi *explicit knowledge* dalam bentuk data terstruktur. Pada penelitian ini, proses eksternalisasi dilakukan mulai dari pengumpulan, pembersihan, dan transformasi data kinerja organisasi. Dataset yang digunakan bersumber dari laporan kinerja periodik unit operasional yang terdokumentasi dalam sistem internal organisasi. Data tersebut mencakup nilai target, realisasi, serta persentase capaian pada setiap indikator kinerja.

Seluruh indikator telah melalui proses identifikasi melalui diskusi manajerial dan evaluasi internal sehingga selaras dengan tujuan strategis organisasi. Dalam penelitian ini, analisis difokuskan pada nilai capaian masing-masing indikator untuk menghasilkan evaluasi yang lebih objektif terhadap tingkat keberhasilan kinerja organisasi yang dapat dilihat pada Tabel 2.

Variabel yang ada pada Tabel 2 digunakan dalam penelitian ini merupakan hasil penyederhanaan dari data awal yang memiliki dimensi deret waktu bulanan. Setelah dilakukan proses pemotongan dan agregasi, atribut yang digunakan dijelaskan sebagai berikut:

1. No_Indikator: sebagai nomor urut untuk mengidentifikasi setiap indikator kinerja secara sistematis.
2. Kode_Indikator: berfungsi untuk kode unik yang merepresentasikan masing-masing indikator kinerja.
3. Bobot: menunjukkan tingkat kontribusi setiap indikator dalam penilaian kinerja secara keseluruhan.
4. Nama_UID: digunakan untuk mengidentifikasi unit induk distribusi (UID) sebagai struktur organisasi.
5. Nama_UP3: merepresentasikan unit UP3 yang menjadi objek evaluasi kinerja.
6. Target: nilai yang harus dicapai dalam periode tertentu, yang diperoleh dari hasil agregasi data bulanan.
7. Realisasi: menunjukkan capaian aktual dari masing-masing indikator, yang diperoleh dari hasil agregasi data bulanan.

Dengan penggunaan variabel tersebut, analisis dapat dilakukan untuk mengevaluasi tingkat pencapaian kinerja setiap unit terhadap target yang telah ditetapkan secara lebih terstruktur dan sistematis. Setelah seluruh proses *preprocessing* selesai, *dataset* dinyatakan siap untuk dianalisis menggunakan metode *Classification Decision Tree* pada RapidMiner. Pada Tabel 3, data telah berada dalam keadaan bersih, konsisten, dan sesuai dengan kebutuhan analisis. *Dataset* akhir terdiri dari sejumlah atribut prediktor sebagai variabel input serta satu atribut label yang berfungsi sebagai target prediksi model. Struktur tersebut memungkinkan algoritma membentuk pola klasifikasi berdasarkan hubungan antara atribut prediktor dan label

yang telah ditentukan, sehingga dapat mengidentifikasi faktor-faktor yang memengaruhi capaian kinerja unit operasional. Komponen dataset yang siap diolah dapat dilihat pada Tabel 3.

Tabel 2. Laporan Data Kinerja

No_In dikator	Kode_Indi kator	Bobot	Nama_UID	Nama_UP3	TARGET_ JAN	...	TARGET_DES	REAL_JAN	...
1	KPI_01	14	UID Jawa Barat		543,28	...	64842,62	5708,25	...
1	KPI_01	14	UID Jawa Barat	UP3 Bandung	379,56	...	4606,13	41,454,863	...
1	KPI_01	14	UID Jawa Barat	UP3 Bekasi	372,35	...	4518,55	40,533,706	...
1	KPI_01	14	UID Jawa Barat	UP3 Bogor	511,92	...	6212,27	54,279,385	...
1	KPI_01	14	UID Jawa Barat	UP3 Cianjur	101,33	...	1229,66	11,531,297	...
1	KPI_01	14	UID Jawa Barat	UP3 Cikarang	729,99	...	8858,63	72,702,087	...
1	KPI_01	14	UID Jawa Barat	UP3 Cimahi	242,33	...	2940,7	26,542,322	...
1	KPI_01	14	UID Jawa Barat	UP3 Cirebon	290,89	...	3530	30,674,521	...
1	KPI_01	14	UID Jawa Barat	UP3 Depok	320,56	...	3890,11	35,974,521	...
1	KPI_01	14	UID Jawa Barat	UP3 Garut	86,1	...	1044,82	10,450,358	...
1	...	...	...	...	...	...	...	...	...
11b	PI_12B	2	UID Jawa Barat	UP3 Tasikmalaya	906,74	...	906,74	198,972,712	...

Tabel 3. Dataset Siap Olah

Kode_Unit	Bulan	Penjualan Tenaga Listrik	SAIDI sesuai Kewenangan- nya	SAIFI sesuai Kewenangan- nya	Susut Distribusi (Tanpa E-min)	Response Time atas Gangguan	Penambah- an Jumlah Pelanggan	Status
UP3BDG	Januari	211,06%	115,59%	100,49%	260,12%	121,98%	113,21%	Baik
UP3BDG	Februari	197,87%	105,85%	83,54%	247,85%	120,30%	107,44%	Baik
UP3BDG	Maret	140,81%	119,00%	100,57%	202,16%	118,35%	97,36%	Baik
UP3BDG	April	123,66%	106,80%	99,08%	158,55%	118,25%	95,77%	Baik
UP3BDG	Mei	104,57%	100,04%	101,83%	133,93%	116,48%	87,76%	Baik
UP3BDG	Juni	99,61%	106,86%	110,76%	122,77%	115,70%	87,63%	Baik
UP3BDG	Juli	99,31%	111,93%	118,34%	115,28%	116,06%	84,61%	Baik
UP3BDG	Agustus	98,76%	106,50%	119,31%	111,35%	116,80%	82,96%	Baik
UP3BDG	September	98,58%	102,95%	120,50%	108,40%	112,42%	81,19%	Baik
UP3BDG	Oktober	98,50%	103,93%	102,90%	102,08%	111,01%	78,87%	Cukup
...	...	...	...	...	...	...	...	...
UP3TSM	Desember	92,28%	115,25%	105,89%	96,77%	145,00%	60,32%	Baik

Variabel yang digunakan dalam dataset pada Tabel 3 merupakan hasil penyederhanaan dari atribut awal yang memiliki nama panjang dan kompleks. Setelah melalui tahap *preprocessing*, atribut yang digunakan dijelaskan sebagai berikut:

1. Kode_Unit: digunakan sebagai identitas unik untuk masing-masing unit yang dianalisis.
2. Bulan: menunjukkan periode waktu pengamatan dalam bentuk data bulanan.
3. Penjualan_Listrik: merepresentasikan energi listrik yang berhasil disalurkan dalam periode tertentu.
4. SAIDI: indikator keandalan sistem distribusi yang menunjukkan rata-rata durasi gangguan pelanggan.
5. SAIFI: menunjukkan frekuensi rata-rata gangguan yang terjadi pada sistem distribusi listrik.
6. Susut_Distribusi: menggambarkan tingkat kehilangan energi listrik selama proses distribusi.
7. Response_Time: merepresentasikan kecepatan unit dalam menangani gangguan yang terjadi.
8. Penambahan_Pelanggan: menunjukkan pertumbuhan jumlah pelanggan dalam periode tertentu.
9. Status: digunakan untuk mengklasifikasikan tingkat pencapaian kinerja unit berdasarkan indikator yang telah ditentukan.

Dengan penggunaan variabel tersebut, analisis dapat dilakukan untuk mengevaluasi dan mengelompokkan kinerja unit secara lebih efektif dan terarah.

3.3 Tahap Kombinasi (*Explicit to Explicit*)

Tahap kombinasi merupakan proses transformasi *explicit knowledge* menjadi pengetahuan eksplisit baru melalui analisis dan pengolahan data. Pada tahap ini, informasi yang telah terdokumentasi dihimpun dan

dianalisis secara sistematis untuk menghasilkan wawasan baru yang lebih komprehensif. Proses analisis dalam penelitian ini dilakukan menggunakan model klasifikasi *Decision Tree* dengan algoritma C4.5.

Variabel yang digunakan terdiri atas variabel identitas, variabel prediktor, dan variabel target. Variabel identitas meliputi Kode_Unit yang berperan sebagai atribut ID pada RapidMiner untuk mengidentifikasi operasional (UP3), serta Bulan sebagai atribut regular yang menunjukkan periode observasi data kinerja. Variabel prediktor terdiri atas enam indikator kinerja yang dinyatakan dalam bentuk persentase capaian, yaitu Penjualan Tenaga Listrik, SAIDI, SAIFI, Susut Distribusi, *Response Time* Gangguan, dan Penambahan Jumlah Pelanggan. Keenam indikator tersebut digunakan sebagai atribut input dalam proses klasifikasi. Sementara itu, variabel target adalah Status Kinerja, yang berperan sebagai label klasifikasi dengan tiga kategori, yaitu Baik, Cukup, dan Kurang.

Pembentukan model diawali dengan menghitung nilai *entropy* untuk mengukur tingkat ketidakpastian data terhadap variabel target. *Dataset* penelitian terdiri atas 204 observasi yang berasal dari 17 unit operasional selama 12 bulan, dengan distribusi kelas 181 data berstatus Baik, 19 data Cukup, dan 4 data Kurang. Untuk hasil perhitungan nilai *entropy* terlihat pada Persamaan 3 berikut:

$$Entropy(S) = -(0,887 \log_2 0,887 + 0,093 \log_2 0,093 + 0,020 \log_2 0,020)$$

$$Entropy(S) = 0,585$$


Berdasarkan distribusi Persamaan 3 tersebut diperoleh nilai *entropy* total sebesar 0,585, yang menunjukkan bahwa tingkat ketidakpastian data relatif rendah karena dominasi kelas Baik. Selanjutnya dilakukan perhitungan *Information Gain* untuk mengetahui kemampuan setiap atribut dalam mengurangi ketidakpastian data.

Pada atribut Kode_Unit, diperoleh nilai *entropy* setelah pemisahan sebesar 0,491, sehingga nilai *Information Gain* yang dihasilkan adalah 0,094. Untuk menghindari bias terhadap atribut dengan jumlah kategori besar, dilakukan normalisasi menggunakan *Gain Ratio* melalui perhitungan *Split Information*. Hasil perhitungan menunjukkan bahwa atribut Kode_Unit memiliki nilai *Split Information* sebesar 4,080 dan nilai *Gain Ratio* sebesar 0,023, yang menunjukkan bahwa atribut tersebut memiliki kontribusi dalam proses pemisahan data.

Model klasifikasi kemudian dibangun menggunakan perangkat lunak RapidMiner dengan *parameter criterion = gain_ratio*, *maximal depth = 10*, dan *minimal leaf size = 2*. Penggunaan kriteria *gain ratio* menunjukkan bahwa algoritma yang digunakan mengacu pada metode C4.5, yang mampu meminimalkan bias terhadap atribut dengan jumlah kategori besar serta menghasilkan pemisahan data yang lebih proporsional. Dalam proses pembentukan pohon keputusan, RapidMiner secara otomatis menghitung nilai *entropy*, *information gain*, dan *split information* untuk menentukan atribut terbaik pada setiap *node*.

3.4 Hasil Model *Decision Tree*

Model *Decision Tree* yang dihasilkan membentuk struktur pohon keputusan seperti terlihat pada Gambar 3 yang terdiri atas satu *root node* sebagai simpul utama dengan nilai *Gain Ratio* tertinggi, sehingga atribut tersebut menjadi faktor paling dominan dalam menentukan kategori kinerja organisasi.



Gambar 3. Pohon Keputusan

Dari simpul utama pada Gambar 3 terbentuk sejumlah percabangan (*split*) yang menggambarkan proses pemisahan data berdasarkan nilai atribut tertentu hingga menghasilkan *leaf node* sebagai keputusan akhir klasifikasi, yaitu kategori Status Kinerja (Baik, Cukup, atau Kurang). Pada setiap *node* juga ditampilkan

jumlah serta distribusi data, sehingga dapat terlihat proporsi unit dalam setiap kategori selama proses pembentukan model. Struktur pohon keputusan yang dihasilkan menunjukkan mekanisme klasifikasi kinerja organisasi secara bertahap, dimulai dari atribut paling berpengaruh pada *root node* kemudian berkembang melalui percabangan sesuai kondisi nilai atribut hingga mencapai *leaf node* sebagai hasil akhir klasifikasi. Seperti terlihat pada Gambar 4, Deskripsi Pohon Keputusan.

```
SAIDI sesuai Kewenangannya > 59.165
|   SAIDI sesuai Kewenangannya > 78.260
|   |   Penjualan Tenaga Listrik > 93.040
|   |   |   SAIDI sesuai Kewenangannya > 82.980
|   |   |   |   SAIDI sesuai Kewenangannya > 106.050: Baik {Baik=153, Cukup=1, Kurang=0}
|   |   |   |   SAIDI sesuai Kewenangannya ≤ 106.050
|   |   |   |   |   Susut Distribusi (Tanpa E-min) > 97.880: Baik {Baik=22, Cukup=1, Kurang=0}
|   |   |   |   |   Susut Distribusi (Tanpa E-min) ≤ 97.880: Cukup {Baik=0, Cukup=2, Kurang=0}
|   |   |   |   |   SAIDI sesuai Kewenangannya ≤ 82.980
|   |   |   |   |   |   SAIFI sesuai Kewenangannya > 89.150: Cukup {Baik=0, Cukup=2, Kurang=0}
|   |   |   |   |   |   SAIFI sesuai Kewenangannya ≤ 89.150: Baik {Baik=2, Cukup=0, Kurang=0}
|   |   |   |   |   |   Penjualan Tenaga Listrik ≤ 93.040
|   |   |   |   |   |   |   Penjualan Tenaga Listrik > 92.455: Cukup {Baik=0, Cukup=3, Kurang=0}
|   |   |   |   |   |   |   Penjualan Tenaga Listrik ≤ 92.455: Baik {Baik=3, Cukup=0, Kurang=0}
|   |   |   |   |   |   |   SAIDI sesuai Kewenangannya ≤ 78.260: Cukup {Baik=1, Cukup=10, Kurang=0}
|   |   |   |   |   |   |   SAIDI sesuai Kewenangannya ≤ 59.165: Kurang {Baik=0, Cukup=0, Kurang=4}
```

Gambar 4. Deskripsi Pohon Keputusan

Terlihat pada Gambar 4, untuk menilai keandalan model yang terbentuk, dilakukan proses evaluasi menggunakan metode *10-fold cross validation*. Metode ini digunakan untuk menguji kemampuan generalisasi model sekaligus meminimalkan risiko *overfitting*, sehingga hasil evaluasi dapat mencerminkan performa model secara lebih objektif. Hasil pengujian terlihat pada Tabel 4 menunjukkan bahwa model *Decision Tree* berbasis algoritma C4.5 memiliki nilai akurasi sebesar 95,62% dengan standar deviasi $\pm 6,18\%$ (*micro average* 95,59%), yang menunjukkan tingkat ketepatan prediksi yang sangat tinggi.

Tabel 4. Rincian Akurasi Model Klasifikasi

	True Baik	True Cukup	True Kurang	Class Precision
Pred. Baik	178	5	0	97.27%
Pred. Cukup	3	13	0	81.25%
Pred. Kurang	0	1	4	80.00%
Class Recall	98.34%	68.42%	100.00%	

Berdasarkan hasil *confusion matrix* pada Tabel 4, performa terbaik terdapat pada kelas Baik dengan 178 prediksi benar, nilai *precision* 97,27%, dan *recall* 98,34%. Pada kelas Cukup, model menghasilkan 13 prediksi benar dengan *precision* 81,25% dan *recall* 68,42%, yang menunjukkan bahwa sebagian data cenderung terklasifikasi sebagai Baik karena memiliki kedekatan nilai indikator. Sementara itu, pada kelas Kurang, model mencapai *recall* 100% dan *precision* 80%, yang menunjukkan kemampuan model yang sangat baik dalam mendeteksi unit dengan kinerja rendah. Secara keseluruhan, hasil evaluasi menunjukkan bahwa model memiliki tingkat akurasi yang sangat baik dengan kesalahan klasifikasi yang relatif kecil, sehingga model ini dapat dimanfaatkan sebagai alat bantu pengambilan keputusan berbasis data dalam menentukan status kinerja unit operasional.

3.5 Tahap Internalisasi (*Explicit to Tacit*)

Tahap internalisasi merupakan proses konversi *explicit knowledge* menjadi *tacit knowledge*, yaitu ketika hasil analisis data dan model klasifikasi tidak hanya dipahami sebagai output teknis, tetapi juga diinterpretasikan sebagai pemahaman manajerial dalam pengelolaan kinerja organisasi. Pada tahap ini, struktur pohon keputusan, aturan klasifikasi, serta hasil evaluasi model menjadi sumber pembelajaran bagi pengambil keputusan.

Interpretasi terhadap struktur pohon keputusan menunjukkan bahwa setiap indikator kinerja memiliki tingkat kontribusi yang berbeda dalam menentukan status kinerja unit. Atribut yang muncul sebagai *root node* merupakan indikator dengan pengaruh paling dominan karena memiliki nilai *Gain Ratio* tertinggi, sedangkan atribut pada percabangan berikutnya tetap berperan dalam membentuk pola klasifikasi. Melalui struktur ini, manajemen dapat memahami bagaimana kombinasi capaian indikator mengarah pada kategori Baik, Cukup, atau Kurang, sehingga hasil model tidak hanya menjelaskan apa yang terjadi, tetapi juga memberikan pemahaman mengenai penyebab suatu unit berada pada kategori kinerja tertentu.

Aturan keputusan yang dihasilkan dari model *Decision Tree* selanjutnya dapat dimanfaatkan sebagai dasar dalam perumusan strategi peningkatan kinerja. Pola yang menghasilkan kategori Kurang dapat dijadikan

prioritas perbaikan, sedangkan kombinasi indikator yang menghasilkan kategori Baik dapat dijadikan *best practice* untuk diterapkan pada unit lain. Dengan demikian, pengambilan keputusan dapat dilakukan secara lebih objektif dan berbasis data, sehingga model klasifikasi yang dihasilkan mampu mendukung proses evaluasi dan perencanaan kinerja organisasi secara berkelanjutan.

3.6 Diskusi

Hasil penelitian menunjukkan bahwa model klasifikasi *Decision Tree* berbasis algoritma C4.5 mampu mencapai tingkat akurasi yang tinggi sebesar 95,62%, yang mengindikasikan kemampuan model dalam mengidentifikasi pola kinerja unit operasional secara baik. Tingginya akurasi ini dipengaruhi oleh karakteristik data yang relatif terstruktur serta dominasi kelas “Baik”, sehingga model lebih mudah mengenali pola mayoritas. Selain itu, penggunaan atribut kinerja yang relevan turut meningkatkan ketepatan klasifikasi. Namun, ketidakseimbangan distribusi data menyebabkan model cenderung kurang optimal dalam memprediksi kelas minoritas seperti “Cukup” dan “Kurang”. Jika dibandingkan dengan penelitian terdahulu, hasil ini sejalan dengan temuan bahwa *Decision Tree* efektif dalam menghasilkan model yang akurat dan mudah diinterpretasikan, khususnya dalam analisis data organisasi. Perbedaannya, penelitian ini tidak hanya berfokus pada aspek klasifikasi, tetapi juga mengintegrasikan hasil analitik ke dalam kerangka manajemen pengetahuan melalui Model SECI.

Selain itu, perbedaan performa metode *K-Means Clustering* dan *regresi linear* dipengaruhi oleh karakteristik data mikroklimat yang kompleks dan dinamis. Pola data yang tidak sepenuhnya *linear* membuat *K-Means* lebih mampu mengidentifikasi segmentasi kondisi lingkungan, terutama dalam mengelompokkan kombinasi variabel yang berkontribusi terhadap emisi karbon tinggi. Sementara itu, *regresi linear* cukup baik dalam memodelkan hubungan kuantitatif, tetapi memiliki keterbatasan dalam menangkap pola *non-linear*. Dari sisi keunggulan, *K-Means* efektif dalam menemukan pola tersembunyi tanpa label, sedangkan *regresi linear* lebih sederhana dan mudah diinterpretasikan. Namun, *K-Means* sensitif terhadap jumlah kluster dan skala data, sedangkan *regresi linear* kurang optimal pada hubungan yang kompleks.

Dengan demikian, kedua metode memberikan pendekatan yang saling melengkapi dalam memahami dan memprediksi emisi karbon. Implikasi penelitian ini menunjukkan bahwa integrasi data mining dan knowledge management dapat mendukung pengambilan keputusan berbasis data secara lebih sistematis. Aturan keputusan dari *Decision Tree* dapat dimanfaatkan sebagai dasar evaluasi dan penyusunan strategi peningkatan kinerja, sementara integrasi dengan Model SECI memungkinkan hasil analitik menjadi pengetahuan eksplisit yang dapat dibagikan dalam organisasi. Meskipun demikian, penelitian ini memiliki keterbatasan, di antaranya ketidakseimbangan distribusi data, penggunaan satu algoritma klasifikasi, serta cakupan data yang masih terbatas pada satu wilayah. Oleh karena itu, penelitian selanjutnya disarankan untuk menerapkan teknik penanganan data imbalance, membandingkan beberapa algoritma, serta memperluas dataset agar menghasilkan model yang lebih *robust* dan *generalizable*.

4. KESIMPULAN

Integrasi manajemen pengetahuan dengan teknik klasifikasi berbasis algoritma C4.5 menunjukkan bahwa data kinerja organisasi dapat diolah menjadi pengetahuan strategis yang mendukung pengambilan keputusan secara lebih objektif dan terstruktur. Melalui pendekatan SECI, proses analitik tidak hanya menghasilkan model klasifikasi, tetapi juga memfasilitasi transformasi pengetahuan menjadi pemahaman manajerial yang dapat digunakan dalam evaluasi kinerja organisasi. Struktur *Decision Tree* yang dihasilkan mampu mengidentifikasi hubungan antar indikator kinerja serta faktor dominan yang menentukan status kinerja unit.

Temuan ini menunjukkan bahwa integrasi *knowledge management* dan *data mining* dapat mendukung praktik *evidence-based decision making* dalam pengelolaan kinerja organisasi. Secara praktis, model yang dihasilkan berpotensi diterapkan sebagai sistem pendukung keputusan untuk pemantauan dan evaluasi kinerja secara periodik. Penelitian selanjutnya dapat mengembangkan studi ini melalui perbandingan dengan algoritma klasifikasi lain, perluasan cakupan data, serta integrasi pendekatan prediktif untuk mendukung perencanaan kinerja jangka panjang.

REFERENSI

- [1] D. K. Njiru, D. M. Mugo, F. M. Musyoka, and W. Murikah, “How knowledge management systems trap dynamic organisations into outdated practices: a systematic review,” *Sci. African*, vol. 29, 2025, doi: 10.1016/j.sciaf.2025.e02946.
- [2] N. Cristache, G. Croitoru, and N. V. Florea, “The influence of knowledge management on innovation and organizational performance,” *J. Innov. Knowl.*, vol. 10, no. 5, p. 100793, Sep. 2025, doi: 10.1016/j.jik.2025.100793.
- [3] E. Novalia Puspardini, “Literature Review: Data Management, Data Analytics, and Business Intelligence for Organization,” *J. Ilmu Komput. Dan Teknol. Inf.*, vol. 2, no. 4, 2024, doi: 10.61132/neptunus.v2i4.429.

- [4] F. A. Al-Alshare, E. Alsariera, B. K. Almagharbeh, M. I. Allahham, R. N. A. Al-Rawashdeh, and N. H. S. Alfawaerh, "The big data analytics to digital marketing path strengthened by knowledge management," *Int. J. Data Netw. Sci.*, vol. 10, no. 1, pp. 137–150, 2026, doi: 10.5267/j.ijdns.2025.10.007.
- [5] A. Haris, "Marketing Knowledge Management Analysis to Drive Innovation and Effective Decision Making," *Adv. Bus. Ind. Mark. Res.*, vol. 3, no. 1, pp. 30–43, 2025, doi: 10.60079/abim.v3i1.415.
- [6] M. Al Fachrozi and K. D. Tania, "Comparison Of Naïve Bayes, SVM, K-NN, Decision Tree, And Random Forest in Sentiment Analysis Based On Seabank Application Aspects," *JURTEKSI (Jurnal Teknol. dan Sist. Informasi)*, vol. XII, no. 1, pp. 69–80, 2025, doi: 10.33330/jurtekxi.v12i1.4189.
- [7] E. Constancio and K. D. Tania, "Penerapan Metode Supervised Learning dan Teknik Resampling untuk Prediksi Penipuan Transaksi Keuangan," *Build. Informatics, Technol. Sci.*, vol. 6, no. 3, pp. 1427–1439, 2024, doi: 10.47065/bits.v6i3.6110.
- [8] I. Assoufi, I. El Farissi, and I. Slimani, "Knowledge Management, Decision-Making and Information and Communication Technology: A Systematic Mapping Study," *Stud. Comput. Intell.*, vol. 1166, pp. 581–591, 2024, doi: 10.1007/978-3-031-65038-3_46.
- [9] H. Noviany, "A Narrative Review of the Integration of Big Data Analytics and Business Intelligence in Organizational Decision-Making," *J. Inf. Syst. Manag. Cit.*, vol. 3, no. 4, pp. 198–210, 2025, doi: 10.61978/data.v3i4.710.
- [10] J. Duque, "Data Mining for Knowledge Management," *Procedia Comput. Sci.*, vol. 239, pp. 257–264, Jan. 2024, doi: 10.1016/j.procs.2024.06.170.
- [11] R. S. Mentari and M. Iqbal, "Student Data Analysis for Decision Making Using Decision Tree," *J. Inf. Technol. Comput. Sci. Electr. Eng.*, vol. 1, no. 3, pp. 517–521, 2024, doi: 10.30596/jitcse.
- [12] K. Istiqomah and V. Sofica, "Penerapan Data Mining Menggunakan Algoritma Decision Tree Untuk Menganalisis Penggunaan Media Sosial Dengan Konsentrasi Belajar Mahasiswa," *RIGGS J. Artif. Intell. Digit. Bus.*, vol. 4, no. 4, pp. 53–67, 2025, doi: 10.31004/riggs.v4i4.3228.
- [13] A. D. M. Saputra and H. Firmansyah, "Implementasi Algoritma Decision Tree untuk Memprediksi Kualitas Udara dan Polusi dengan RapidMiner," *J. Tek. Inform.*, vol. 4, no. 3, pp. 212–219, 2025, doi: 10.56211/sudo.v4i3.1145.
- [14] A. Setyawan, A. Fitriani, and E. Rilvani, "Klasifikasi Kemiskinan di Indonesia dengan Decision Tree menggunakan Rapidminer," *J. MEDIA Akad.*, vol. 3, no. 7, pp. 3031–5220, 2025, doi: <https://doi.org/10.62281/v3i7.2646>.
- [15] U. Al Faruq, M. Ainun Naja Fauzi, I. Fatayasya, E. Daniati, and A. Ristyawan, "Prediksi Data Kelulusan Mahasiswa Dengan Metode Decision Tree menggunakan Rapidminer," *Pros. SEMNAS INOTEK (Seminar Nas. Inov. Teknol.)*, vol. 8, no. 1, pp. 131–138, 2024, doi: 10.29407/inotek.v8i1.4919.
- [16] Z. Fatah and S. Bella, "Klasifikasi Status Akademik Mahasiswa Menggunakan Decision Tree," *J. Mhs. Tek. Inform.*, vol. 4, no. 2, pp. 141–146, 2025, doi: 10.35473/jamastika.v4i2.4523.
- [17] E. López-Meza, A. Terán-Bustamante, and S. N. Leyva-Hernández, "SECI model of knowledge management: A thematic analysis with emphasis on agricultural organizations," *Iberoam. J. Sci. Meas. Commun.*, vol. 4, no. 2, 2024, doi: 10.47909/ijsmc.133.
- [18] A. Y. Alchilma, I. Z. Nahdhiana, N. S. Nabila, and P. P. Danur, "Enhancing Knowledge Management Quality in School through the SECI Model," *JENTRE J. Educ. Adm. Train. Relig.*, vol. 5, no. 2, 2025, doi: 10.38075/jen.v5i2.491.
- [19] Z. S. Nugraha, I. T. Wibowo, Maulana Asykari Muhammad, and Yuni Sugiarti, "Perancangan Knowledge Management System Resep Masakan Indonesia Menggunakan Model SECI," *J. Ilm. Inform. Glob.*, vol. 15, no. 3, pp. 116–123, 2024, doi: 10.36982/jiig.v15i3.4885.
- [20] Y. Chen, X. Pan, P. Liu, and W. Vanhaverbeke, "How does digital transformation empower knowledge creation? Evidence from Chinese manufacturing enterprises," *J. Innov. Knowl.*, vol. 9, no. 2, p. 100481, 2024, doi: 10.1016/j.jik.2024.100481.