

Optimasi Strategi Inventory dan Mitigasi Knowledge Loss pada Industri Otomotif Melalui Integrasi Algoritma K-Means Clustering dan Framework SECI

Violin Juneyla Nandita¹, Juseia Wulandari^{2,*}, Khairunnisa' Almaududy³, Muhammad Rafi Herdian⁴,
Ken Ditha Tania⁵, Ahmad Rifai⁶, Dedy Kurniawan⁷

Fakultas Ilmu Komputer, Sistem Informasi, Universitas Sriwijaya, Palembang, Indonesia
Email: ¹violinjuneyla06@gmail.com, ^{2,*}juseiawulandari59@gmail.com, ³khairunnisaalmaududy@gmail.com,
⁴rafiherdian06@gmail.com, ⁵kenya.tania@gmail.com, ⁶ahmadrifai@unsri.ac.id, ⁷dedykurniawan@unsri.ac.id
Email Penulis Korespondensi: juseiawulandari59@gmail.com

Submitted 09-03-2026; Accepted 06-05-2026; Published 30-06-2026

Abstrak

Transformasi digital dalam industri otomotif bekas saat ini menuntut pergeseran paradigma dari pengambilan keputusan yang bersifat intuitif menuju pendekatan berbasis data guna menghadapi dinamika persaingan pasar yang semakin ketat. Masalah utama yang ditemukan dalam penelitian ini adalah tingginya tingkat subjektivitas dalam pengelolaan stok serta ketergantungan pada pengalaman individu yang memicu risiko hilangnya pengetahuan organisasi atau kehilangan pengetahuan. Penelitian ini bertujuan untuk mengoptimalkan strategi manajemen persediaan dan memitigasi risiko tersebut melalui integrasi algoritma pengelompokan K-Means dan kerangka kerja Socialization, Externalization, Combination, Internalization. Metode penelitian melibatkan analisis mendalam terhadap lima ratus lima puluh delapan ribu delapan ratus tiga puluh tujuh data transaksi kendaraan menggunakan teknik penambangan data untuk menemukan pola tersembunyi dari perilaku pasar otomotif. Hasil penelitian menunjukkan bahwa algoritma tersebut berhasil mengelompokkan stok menjadi tiga kelompok optimal, di mana simbol k merepresentasikan jumlah kelompok sebanyak tiga, dengan performa tinggi yang dibuktikan oleh skor Indeks Calinski-Harabasz sebesar 283.364,95. Kelompok tersebut membedakan aset menjadi kategori menengah, risiko tinggi, dan premium berdasarkan kondisi fisik serta jarak tempuh, yang memungkinkan perusahaan menentukan strategi likuidasi atau retensi secara akurat. Integrasi dengan kerangka kerja tersebut memastikan temuan penambangan data ditransformasi menjadi manajemen pengetahuan organisasi yang terdokumentasi secara permanen. Implementasi model ini memberikan dampak signifikan bagi perusahaan dalam meningkatkan efisiensi operasional dan mengurangi ketergantungan pada memori individu. Penelitian ini memberikan kontribusi nyata dalam menciptakan landasan objektif bagi pengambilan keputusan manajerial yang lebih terukur, sistematis, dan berkelanjutan bagi industri.

Kata Kunci: Penambangan Data; Model SECI; Manajemen Pengetahuan; Kehilangan Pengetahuan; Pengelompokan K-Means

Abstract

Digital transformation within used automotive industry today demands paradigm shift from intuitive decision-making towards data-driven approach to face increasingly intense market competition dynamics. The primary problem identified in this research is high level of subjectivity in stock management and dependence on individual experience triggering organizational knowledge loss risks or knowledge loss. This study aims to optimize stock management strategy and mitigate these risks through integration of K-Means clustering algorithm and Socialization, Externalization, Combination, Internalization framework. The research method involves in-depth analysis of five hundred fifty-eight thousand eight hundred thirty-seven vehicle transaction data using data mining techniques to discover hidden patterns from automotive market behavior. Research results show that the algorithm successfully classified stock into three optimal clusters, where symbol k represents cluster number of three, with high performance proven by Calinski-Harabasz Index score of 283,364.95. These clusters differentiate assets into medium, high-risk, and premium categories based on physical condition and mileage, which allows companies to determine liquidation or retention strategies accurately. Integration with the framework ensures that data mining findings are transformed into permanently documented organizational knowledge management. The implementation of this model provides a significant impact for companies in improving operational efficiency and reducing dependence on individual memory. This research study provides a real contribution in creating an objective foundation for more measurable, systematic, and sustainable managerial decision-making for national industry sectors and other related complex business environment systems.

Keywords: Data Mining; SECI Model; Knowledge Management; Knowledge Loss; K-Means Clustering

1. PENDAHULUAN

Pengelolaan persediaan merupakan salah satu fungsi operasional yang paling menentukan keberhasilan bisnis dalam industri otomotif. Tidak seperti sektor lain yang mungkin lebih fleksibel dalam menghadapi ketidaksesuaian antara pasokan dan permintaan, industri otomotif beroperasi dalam lingkungan yang sangat sensitif terhadap ketepatan alokasi stok. Kendaraan memiliki nilai tinggi, membutuhkan ruang penyimpanan yang signifikan, dan mengalami perubahan permintaan yang dipengaruhi oleh berbagai faktor eksternal seperti tren pasar, kebijakan fiskal, hingga pergeseran preferensi konsumen. Dalam kondisi tersebut, kesalahan dalam memperkirakan jumlah dan jenis kendaraan yang harus tersedia di setiap titik distribusi dapat menimbulkan konsekuensi yang luas, mulai dari penumpukan stok yang membebani arus kas perusahaan hingga kekurangan pasokan yang berujung pada hilangnya peluang penjualan dan menurunnya kepuasan pelanggan. Ketidaktepatan alokasi persediaan dengan demikian bukan hanya persoalan teknis, melainkan menyangkut efisiensi distribusi secara keseluruhan dan kualitas perencanaan operasional jangka pendek maupun menengah [1].

Seiring berkembangnya kapasitas pengumpulan dan pemrosesan data dalam skala besar, pendekatan berbasis data mulai diadopsi secara luas sebagai solusi atas permasalahan tersebut. Data transaksi penjualan, catatan pergerakan stok, pola permintaan per wilayah, hingga histori pengiriman antardepot menyimpan informasi berharga yang apabila diolah secara sistematis dapat menghasilkan gambaran yang jauh lebih akurat mengenai dinamika persediaan. Analitik data memungkinkan organisasi untuk beralih dari pengambilan keputusan yang bertumpu pada intuisi manajerial semata menuju pendekatan yang lebih terstruktur dan dapat dipertanggungjawabkan secara empiris. Salah satu teknik yang paling banyak dimanfaatkan dalam konteks ini adalah klusterisasi, yaitu suatu metode pembelajaran mesin tanpa supervisi yang mengelompokkan data berdasarkan kemiripan karakteristik intrinsiknya, tanpa memerlukan label atau kategori yang telah ditentukan sebelumnya [2], [3].

Di antara berbagai algoritma klusterisasi yang tersedia, K-Means telah terbukti menjadi pilihan yang efektif dan efisien dalam mengolah dataset berskala besar. Algoritma ini bekerja dengan cara membagi data ke dalam sejumlah kelompok yang telah ditentukan, di mana setiap anggota kelompok memiliki kedekatan yang lebih besar terhadap pusat klasternya sendiri dibandingkan dengan pusat klaster lainnya. Dalam konteks persediaan otomotif, K-Means dapat digunakan untuk mengelompokkan jenis kendaraan berdasarkan pola pergerakan stok, kecepatan penjualan, atau kontribusi terhadap pendapatan. Misalnya, kendaraan dengan volume penjualan tinggi dan perputaran cepat dapat diidentifikasi sebagai kelompok prioritas yang memerlukan ketersediaan stok lebih konsisten, sementara model dengan penjualan lambat atau bersifat musiman dapat dikelola dengan strategi pengadaan yang lebih konservatif. Kajian komparatif menunjukkan bahwa K-Means umumnya lebih unggul dibandingkan K-Medoids dari sisi efisiensi komputasi, dengan nilai Davies-Bouldin Index yang lebih baik, sekaligus memberikan fleksibilitas yang memadai dalam pengaturan parameter klaster [4]. Meskipun beberapa pendekatan alternatif seperti DBSCAN dan Agglomerative Clustering juga menunjukkan keunggulan pada kondisi distribusi data tertentu, tidak ada satu algoritma yang secara universal superior dalam seluruh konteks [5]. Artinya, pemilihan metode harus didasarkan pada karakteristik data yang dihadapi, dan dalam kasus data persediaan otomotif yang cenderung terstruktur dan berdimensi terbatas, K-Means tetap menjadi pilihan yang tepat secara metodologis.

Sejumlah penelitian juga menegaskan bahwa penerapan model Business Intelligence berbasis data dapat memperkuat kapasitas organisasi dalam mengekstrak wawasan strategis dari data sektoral, yang pada akhirnya mendukung kualitas pengambilan keputusan manajerial [6], [7], [8]. Namun demikian, semakin banyaknya bukti empiris mengenai keunggulan analitik data tidak serta-merta berarti bahwa pendekatan ini mampu menjawab seluruh tantangan yang dihadapi organisasi. Terdapat dimensi penting yang kerap luput dari perhatian, yaitu bagaimana hasil analisis tersebut dapat bertahan dalam organisasi, diwariskan antargenerasi karyawan, dan ditransformasikan menjadi pengetahuan yang dapat digunakan kembali dalam jangka panjang.

Salah satu tantangan yang justru semakin mendesak dalam industri otomotif adalah hilangnya pengetahuan organisasi akibat dinamika sumber daya manusia. Ketika seorang mekanik senior pensiun setelah dua puluh tahun bekerja, ia membawa serta pemahaman mendalam mengenai karakteristik produk, pola permintaan pelanggan setia, hingga kebiasaan distributor di wilayah tertentu. Demikian pula ketika rotasi pekerjaan dilakukan terlalu cepat, pengetahuan tacit yang telah dibangun melalui pengalaman bertahun-tahun menjadi sulit untuk dialihkan kepada penerus. Pengetahuan tacit, yang bersifat personal, kontekstual, dan sulit diartikulasikan secara eksplisit, merupakan aset organisasi yang sangat berharga sekaligus sangat rentan terhadap kehilangan [9], [10]. Kehilangan pengetahuan semacam ini berdampak langsung pada kualitas pengambilan keputusan, kapasitas organisasi untuk berinovasi, dan keberlangsungan operasional dalam jangka panjang.

Untuk merespons tantangan ini, kerangka kerja manajemen pengetahuan telah dikembangkan sebagai mekanisme sistematis guna menangkap, menyimpan, dan menyebarkan pengetahuan di dalam organisasi. Salah satu model yang paling relevan dan banyak digunakan adalah model SECI yang diperkenalkan oleh Nonaka dan Takeuchi, yang mendeskripsikan siklus konversi pengetahuan melalui empat tahapan: Socialization, Externalization, Combination, dan Internalization. Dalam konteks industri otomotif, model ini dapat dipahami sebagai proses di mana wawasan yang diperoleh dari pengalaman sehari-hari di lantai penjualan atau gudang distribusi (sosialisasi) diangkat ke permukaan melalui diskusi dan dokumentasi (eksternalisasi), kemudian dikombinasikan dengan data dan prosedur formal yang ada (kombinasi), dan akhirnya diserap kembali oleh anggota organisasi sebagai bagian dari kompetensi mereka (internalisasi). Dengan mekanisme ini, pengetahuan tidak lagi bergantung pada individu tertentu, melainkan menjadi milik bersama yang dapat diwariskan dan dikembangkan secara berkelanjutan [11], [12].

Meskipun kedua pendekatan ini, yaitu analitik data dan manajemen pengetahuan, sama-sama memiliki relevansi yang kuat dalam konteks industri otomotif, literatur yang ada cenderung memperlakukan keduanya sebagai domain yang sepenuhnya terpisah. Studi-studi berbasis data berfokus pada peningkatan efisiensi operasional dan akurasi keputusan melalui pemrosesan informasi kuantitatif, sementara penelitian di bidang manajemen pengetahuan lebih memusatkan perhatian pada keberlanjutan pengetahuan organisasi dan mitigasi risiko kehilangan keahlian [10], [13]. Akibatnya, hasil klusterisasi yang dihasilkan dari analisis data persediaan kerap kali berhenti sebagai temuan teknis yang digunakan untuk keputusan jangka pendek, tanpa pernah diinstitutionalisasi sebagai bagian dari basis pengetahuan organisasi. Kesenjangan ini mencerminkan kebutuhan mendesak akan suatu pendekatan terpadu yang mampu menjembatani kekuatan analitik kuantitatif dengan mekanisme transformasi pengetahuan yang terstruktur.

Untuk mengatasi kesenjangan tersebut, penelitian ini mengusulkan kerangka kerja terintegrasi yang menggabungkan klusterisasi K-Means dengan model manajemen pengetahuan SECI dalam satu sistem yang koheren. K-Means digunakan untuk mengidentifikasi pola-pola strategis dalam data persediaan otomotif secara objektif dan dapat

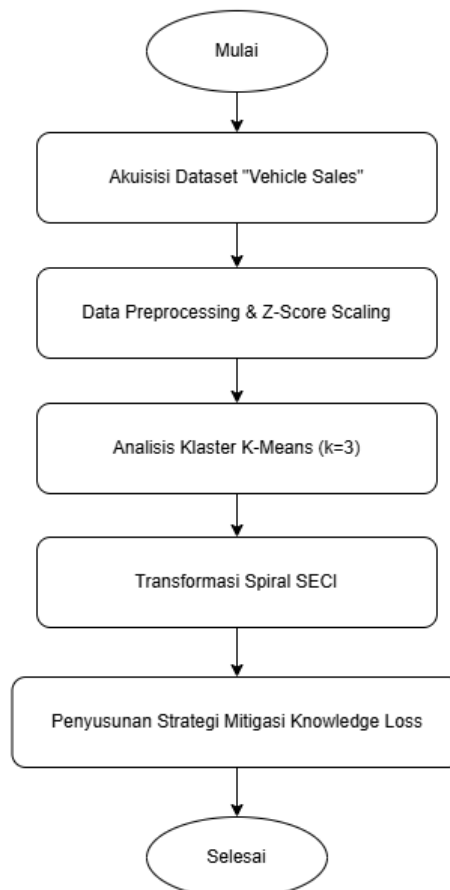
direplikasi, sementara kerangka SECI berperan dalam mentransformasikan temuan-temuan tersebut menjadi pengetahuan organisasi yang terstruktur, mudah diakses, dan dapat diterapkan secara berkelanjutan. Integrasi ini memastikan bahwa insight yang dihasilkan dari analisis tidak hanya bermanfaat sesaat, tetapi juga tertanam dalam memori kolektif organisasi sehingga dapat mengurangi risiko kehilangan pengetahuan di masa mendatang.

Berdasarkan kerangka tersebut, penelitian ini bertujuan untuk mengoptimalkan strategi persediaan dalam industri otomotif melalui integrasi metodologis antara klusterisasi K-Means dan kerangka SECI, dengan fokus pada identifikasi pola bermakna dari data penjualan kendaraan serta transformasinya menjadi pedoman pengetahuan yang dapat digunakan secara organisasional. Kontribusi ilmiah utama penelitian ini terletak pada pengembangan pendekatan manajemen pengetahuan berbasis data yang menjembatani analitik kuantitatif dengan transformasi pengetahuan kualitatif, sebuah pendekatan yang belum banyak dieksplorasi dalam literatur yang ada. Secara praktis, pendekatan ini diharapkan mampu meningkatkan efisiensi pengelolaan persediaan, memperkuat adaptivitas organisasi terhadap perubahan pasar, dan mendukung daya saing jangka panjang perusahaan otomotif dalam lanskap bisnis yang semakin dinamis dan berbasis data.

2. METODOLOGI PENELITIAN

2.1 Kerangka Kerja Penelitian

Kerangka Kerja Penelitian ini dirancang dengan alur kerja sistematis yang mengintegrasikan teknik analitik data dan manajemen pengetahuan guna memitigasi risiko *knowledge loss* pada industri otomotif. Pendekatan ini memastikan bahwa setiap informasi teknis yang dihasilkan dapat dikonversi menjadi aset pengetahuan strategis bagi perusahaan [14]. Tahapan penelitian secara visual, mulai dari akuisisi dataset hingga perumusan strategi mitigasi melalui model SECI, disajikan pada Gambar 1.



Gambar 1. Kerangka Kerja Penelitian Integrasi K-Means dan SECI

Berdasarkan alur pada Gambar 1, setiap tahapan dirancang untuk memastikan distribusi pengetahuan yang merata. Penggunaan model SECI menjamin bahwa hasil klusterisasi tidak hanya menjadi output teknis, tetapi diinternalisasi menjadi standar operasional prosedur [15]. Hal ini krusial untuk menjaga keberlangsungan pengetahuan agar tidak hilang saat terjadi pergantian personel dalam organisasi [16].

2.2 Teknik Pengumpulan Data

Penelitian ini menggunakan pendekatan kuantitatif dengan data sekunder berupa dataset transaksi penjualan kendaraan (Vehicle Sales) sebanyak 558.837 baris transaksi. Penggunaan data historis berskala besar sangat krusial dalam domain data mining untuk mengidentifikasi pola konsumsi dan tren penjualan yang berulang [17], [18], sehingga mendukung pengambilan keputusan strategis terkait manajemen stok dan distribusi produk [17]. Tiga variabel utama diekstraksi untuk proses klusterisasi:

- Condition*: Mewakili skor penilaian fisik kendaraan dalam rentang 1 hingga 50. Variabel ini menjadi indikator kualitas aset.
- Odometer*: Menunjukkan jarak tempuh kendaraan. Jarak tempuh merupakan faktor kunci yang menentukan depresiasi nilai sebuah kendaraan otomotif.
- Selling Price*: Harga jual akhir kendaraan. Variabel ini digunakan sebagai parameter nilai ekonomi aset dalam gudang persediaan.

Data yang terkumpul kemudian disimpan dalam format *.csv* untuk kemudian diproses menggunakan bahasa pemrograman Python dan pustaka analisis data seperti Pandas dan Scikit-Learn.

2.3 Pra-pemrosesan Data

Tahap pra-pemrosesan merupakan langkah yang sangat menentukan kualitas akhir dari hasil pengelompokan kluster [19]. Proses *cleaning* menjadi langkah awal yang vital dalam mengelola data bervolume besar. Dengan mengatasi *missing values* dan mendeteksi data duplikat sejak dini, kita bisa memastikan bahwa hasil analisis yang diperoleh benar-benar akurat dan reliabel [18]. Proses ini memastikan bahwa hanya data yang valid dan konsisten yang akan diproses pada tahap selanjutnya.

Langkah krusial berikutnya adalah transformasi data melalui teknik normalisasi. Karena variabel *Odometer* memiliki skala puluhan ribu sementara variabel *Condition* hanya bernilai satuan, maka dilakukan standarisasi menggunakan *StandardScaler* [20]. Proses ini mengubah distribusi data sehingga memiliki rata-rata nol dan varians satu dengan rumus matematis:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

Dimana:

- z : Nilai hasil standarisasi (*z-score*).
- x : Nilai asli data (harga/odometer).
- μ : Nilai rata-rata variabel.
- σ : Standar deviasi variabel.

Tanpa adanya normalisasi, fitur dengan nominal angka yang besar akan mendominasi perhitungan jarak dalam algoritma, sehingga hasil klustering menjadi tidak akurat dan tidak merepresentasikan kondisi nyata [20].

2.4 Algoritma K-Means dan Penentuan Kluster Optimal

Algoritma K-Means dipilih karena keunggulannya dalam skalabilitas, sehingga proses pengolahan data bervolume besar dapat dilakukan secara efisien tanpa memakan waktu komputasi yang signifikan, serta kemampuannya dalam mempartisi data secara non-hierarki ke dalam kelompok-kelompok berdasarkan kesamaan atribut [18]. Keunggulan ini sejalan dengan temuan empiris yang membuktikan bahwa K-Means mampu menghasilkan pengelompokan yang optimal pada data penjualan berskala besar dengan pola distribusi yang beragam [19], sehingga menjadikannya pilihan yang tepat untuk mengolah dataset Vehicle Sales yang terdiri dari 558.837 transaksi dalam penelitian ini.

Proses clustering diawali dengan identifikasi nilai k optimal melalui pendekatan Elbow Method dengan mengevaluasi nilai Within-Cluster Sum of Squares (WCSS). Teknik ini dipilih untuk memastikan jumlah kluster yang ditentukan benar-benar merepresentasikan struktur data secara akurat tanpa mengalami overfitting [21]. Titik "siku" pada grafik distorsi menandakan bahwa penambahan kluster lebih lanjut tidak lagi memberikan pengurangan kesalahan yang signifikan, sehingga keputusan penentuan jumlah kluster bersifat objektif dan terukur secara matematis [21]. Untuk mempercepat konvergensi dan memastikan stabilitas posisi centroid, inisialisasi dilakukan menggunakan metode *k-means++* yang terbukti menghasilkan posisi awal centroid yang lebih representatif dibandingkan inisialisasi acak [18]. Selanjutnya, setiap observasi didistribusikan ke kluster berdasarkan perhitungan Jarak Euclidean, dan iterasi dilakukan hingga posisi centroid tidak lagi berubah guna meminimalkan deviasi antara titik data dengan centroid yang bersesuaian [17].

Untuk memvalidasi kualitas hasil clustering secara kuantitatif dan memastikan bahwa pemilihan K-Means dapat dipertanggungjawabkan secara ilmiah, evaluasi dilakukan menggunakan tiga metrik komplementer. Silhouette Score mengukur seberapa mirip suatu observasi dengan klasternya sendiri dibandingkan kluster lain, dengan nilai mendekati +1 mengindikasikan pemisahan kluster yang baik. Davies-Bouldin Index (DBI) mengukur rasio jarak rata-rata dalam kluster terhadap jarak antar centroid, di mana nilai yang lebih rendah mencerminkan kluster yang lebih kompak dan terpisah dengan baik — sebagaimana dibuktikan oleh Akhda & Tania [4] dalam konteks evaluasi algoritma clustering pada data publik berskala besar. Calinski-Harabasz Index (CHI) mengukur rasio varians antar kluster terhadap varians dalam kluster, sehingga nilai yang lebih tinggi mengindikasikan definisi kluster yang lebih optimal. Penggunaan ketiga metrik ini secara

simultan memberikan perspektif evaluasi yang lebih komprehensif karena masing-masing metrik sensitif terhadap aspek kualitas clustering yang berbeda, sehingga kesimpulan yang dihasilkan tidak bergantung pada satu sudut pandang evaluasi saja.

Sebagai upaya memperkuat validitas pemilihan algoritma, K-Means juga dibandingkan secara komparatif dengan Gaussian Mixture Model (GMM) menggunakan jumlah komponen yang sama ($k=3$). GMM dipilih sebagai pembanding karena secara algoritmik merupakan generalisasi probabilistik dari K-Means — di mana K-Means pada dasarnya adalah kasus khusus GMM dengan asumsi komponen yang seimbang dan matriks kovarian spherical yang homogen [22]. Berbeda dengan K-Means yang menerapkan hard clustering, GMM mengestimasi parameter distribusi melalui algoritma Expectation-Maximization (EM) dan memberikan probabilitas keanggotaan bagi setiap observasi terhadap seluruh komponen secara simultan, sehingga mampu menangkap struktur data yang lebih kompleks [22]. Perbandingan kedua metode ini secara langsung mengukur dampak pelanggaran asumsi rigid K-Means terhadap kualitas segmentasi, sehingga pemilihan K-Means sebagai metode utama tidak hanya didasarkan pada pertimbangan komputasional, tetapi juga terbukti secara kuantitatif melalui ketiga metrik evaluasi yang digunakan.

2.5 Pemetaan Framework SECI (*Socialization, Externalization, Combination, Internalization*)

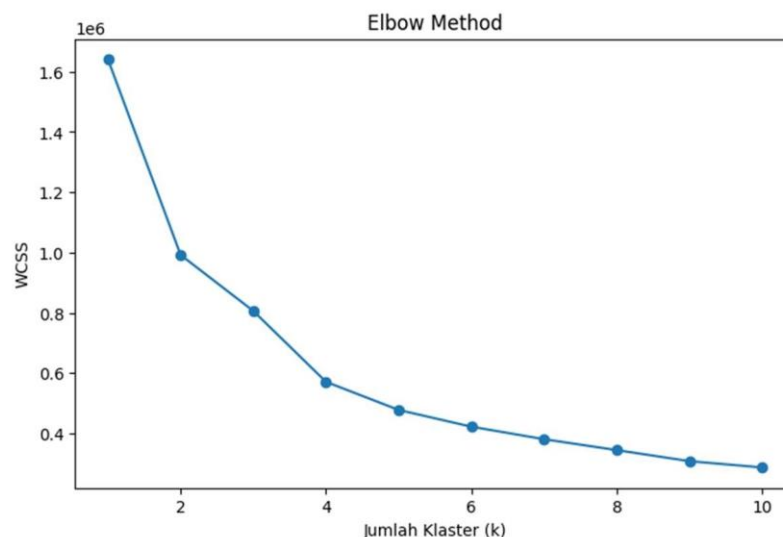
Profil kluster hasil K-Means dipetakan ke dalam empat dimensi konversi pengetahuan framework SECI untuk memitigasi knowledge loss organisasi secara permanen [16]:

- Socialization*: Tahap berbagi pengetahuan *tacit* melalui interaksi sosial, seperti diskusi tim untuk mendalami makna di balik angka-angka kluster kendaraan yang ditemukan [16].
- Externalization*: Mengubah pengetahuan *tacit* menjadi format eksplisit yang nyata, misalnya dengan mendokumentasikan karakteristik tiap kluster ke dalam pedoman strategi stok atau forum diskusi agar dapat diakses oleh karyawan lain [16].
- Combination*: Pengetahuan eksplisit baru tersebut digabungkan dengan sistem manajemen dokumen dan basis data perusahaan yang sudah ada, sehingga menciptakan sistem pendukung keputusan yang terintegrasi secara digital [16].
- Internalization*: Proses di mana karyawan mempelajari kembali dokumentasi hasil analisis klustering tersebut untuk diserap kembali menjadi pengetahuan *tacit* atau kompetensi organisasi yang baru, guna menjamin keberlangsungan operasional jangka panjang [16].

3. HASIL DAN PEMBAHASAN

3.1 Analisis Pengelompokan Data (Clustering)

Langkah awal dalam proses analisis adalah menentukan jumlah kluster yang paling tepat untuk dataset *Vehicle Sales* yang terdiri dari 558.837 transaksi. Penentuan ini dilakukan secara objektif menggunakan metode *Elbow Method* dengan parameter *Within-Cluster Sum of Squares* (WCSS). Hasil pengujian nilai k tersebut ditampilkan pada Gambar 2.



Gambar 2. Hasil Uji *Elbow Method* untuk Penentuan Nilai k

Berdasarkan hasil uji *Elbow Method*, terlihat bahwa penurunan nilai WCSS mengalami titik kelengkungan (*elbow*) yang paling signifikan pada jumlah kluster $k=3$. Hasil ini menunjukkan bahwa pembagian dataset ke dalam tiga kelompok merupakan representasi paling stabil dan optimal untuk variabel *Condition*, *Odometer*, dan *Selling Price*. Penentuan jumlah kluster menggunakan *Elbow Method* dilakukan dengan mengidentifikasi titik kelengkungan (*elbow point*), yang merupakan langkah krusial dalam menjaga keseimbangan antara kompleksitas model dan kualitas segmentasi [2], [23]. Dalam konteks penelitian ini, pemilihan $k=3$ tidak hanya memenuhi kriteria matematis, tetapi juga relevan secara

manajerial karena mampu merepresentasikan variasi inventory kendaraan berdasarkan tingkat risiko dan nilai ekonominya.

3.2.1 Evaluasi Kualitas Klaster dan Analisis Komparatif

Meskipun Elbow Method memberikan dasar penentuan jumlah klaster secara visual, validasi kualitas hasil clustering secara kuantitatif tetap diperlukan agar kesimpulan yang dihasilkan tidak bergantung pada interpretasi grafik semata. Oleh karena itu, evaluasi dilakukan menggunakan tiga metrik komplementer, yaitu Silhouette Score, Davies-Bouldin Index (DBI), dan Calinski-Harabasz Index (CHI). Ketiga metrik ini dipilih karena masing-masing mengukur aspek kualitas clustering yang berbeda — Silhouette Score menilai kohesi dan separasi klaster secara bersamaan, DBI mengukur rasio jarak dalam klaster terhadap jarak antar centroid, sedangkan CHI mengukur rasio varians antar klaster terhadap varians dalam klaster — sehingga evaluasi yang dihasilkan bersifat menyeluruh dan tidak bias terhadap satu perspektif saja.

Selain evaluasi internal, pengujian komparatif juga dilakukan dengan membandingkan K-Means terhadap Gaussian Mixture Model (GMM) menggunakan jumlah komponen yang sama ($k=3$) agar perbandingan bersifat adil dan objektif. Evaluasi dilakukan menggunakan metrik *Silhouette Score*, *Davies-Bouldin Index* (DBI), dan *Calinski-Harabasz Index* (CHI) untuk membandingkan performa K-Means terhadap *Gaussian Mixture Model* (GMM), sebagaimana dirangkum dalam Tabel 1. Perbandingan Metrik Evaluasi Clustering K-Means dan Gaussian Mixture Model.

Tabel 1. Perbandingan Metrik Evaluasi Clustering K-Means dan Gaussian Mixture Model

Metode	Pendekatan	<i>Silhouette Score</i>	<i>Davies-Bouldin Index</i>	<i>Calinski-Harabasz Index</i>
K-Means ($k=3$)	<i>Hard Clustering</i>	0,3295	1,0978	283.364,95
GMM ($k=3$)	<i>Soft Clustering</i>	0,3373	1,1231	259.418,41

Berdasarkan Tabel 1, K-Means menunjukkan keunggulan pada dua dari tiga metrik evaluasi. Nilai DBI K-Means sebesar 1,0978 lebih rendah dibandingkan GMM sebesar 1,1231, yang berarti klaster yang dihasilkan K-Means memiliki pemisahan antar kelompok yang lebih baik dengan variasi internal yang lebih kecil. Perbedaan yang lebih substansial terlihat pada nilai CHI, di mana K-Means menghasilkan 283.364,95 sementara GMM hanya mencapai 259.418,41. Selisih sebesar ± 24.000 poin ini mengindikasikan bahwa klaster K-Means memiliki kepadatan internal dan separasi antar klaster yang secara signifikan lebih optimal. Meskipun GMM menghasilkan *Silhouette Score* yang sedikit lebih tinggi (0,3373 vs 0,3295), selisih sebesar 0,0078 tidak cukup signifikan untuk mengubah kesimpulan secara keseluruhan. Dengan mempertimbangkan keunggulan K-Means secara dominan pada metrik DBI dan CHI, algoritma K-Means terbukti secara kuantitatif sebagai metode yang paling sesuai untuk segmentasi inventory kendaraan pada dataset ini.

Hasil evaluasi ini sejalan dengan temuan pada penelitian sejenis yang dilakukan oleh Akhda & Tania [4], yang menerapkan K-Means pada data kemiskinan di Sumatera Selatan menggunakan variabel rata-rata lama sekolah, jumlah penduduk miskin, dan pengeluaran per kapita. Dalam penelitian tersebut, K-Means menghasilkan nilai DBI optimal sebesar 0,204 pada $K=5$, yang terbukti lebih unggul dibandingkan K-Medoids dengan DBI sebesar 0,239 pada jumlah klaster yang sama. Keunggulan K-Means dalam penelitian tersebut dikaitkan dengan karakteristik dataset yang relatif homogen dan minim outlier, sehingga pendekatan berbasis centroid bekerja lebih optimal. Kondisi serupa terjadi dalam penelitian ini, di mana K-Means pada dataset Vehicle Sales menghasilkan DBI sebesar 1,0978, lebih rendah dibandingkan GMM sebesar 1,1231. Meskipun nilai DBI absolut berbeda — yang wajar mengingat perbedaan skala dataset, jumlah variabel, dan domain penelitian — pola konsistensi keunggulan K-Means dalam menghasilkan klaster yang lebih kompak dan terpisah dengan baik terkonfirmasi pada kedua konteks tersebut. Hal ini memperkuat validitas pemilihan K-Means sebagai metode utama dalam penelitian ini, sekaligus menunjukkan bahwa algoritma K-Means memiliki kemampuan generalisasi yang baik lintas domain data, mulai dari data sosio-ekonomi hingga data inventory kendaraan berskala besar.

Dengan jumlah data yang sangat besar, yaitu lebih dari 500 ribu transaksi, stabilitas jumlah klaster menunjukkan bahwa model tidak mengalami over-segmentation maupun under-segmentation, sehingga hasil klasifikasi dapat digunakan sebagai fondasi pengambilan keputusan strategis. Segmentasi menjadi tiga kategori utama juga mempermudah manajemen dalam menyusun kebijakan yang berbeda untuk setiap kelompok tanpa menambah kompleksitas analisis, sejalan dengan pendekatan optimasi inventory modern yang menekankan pentingnya pengelompokan stok berdasarkan karakteristik nilai dan risiko. Dalam konteks industri otomotif yang dinamis, klasifikasi berbasis data seperti ini menjadi elemen penting dalam mengubah data transaksi yang sangat besar menjadi informasi strategis untuk memahami pola pergerakan stok, memprediksi potensi penurunan nilai kendaraan, serta memperkirakan kebutuhan strategi promosi penjualan. Oleh karena itu, tahap analisis clustering ini menjadi fondasi utama dalam keseluruhan proses analisis dan berperan sebagai jembatan antara data mining dan pengambilan keputusan manajerial.

3.2 Pembahasan Karakteristik Klaster (Centroid Profiling)

Setelah model divalidasi dan dipilih sebagai metode terbaik, langkah selanjutnya adalah mendalami karakteristik unik dari setiap kelompok yang terbentuk. Analisis terhadap nilai rata-rata (*centroid*) dilakukan guna memahami profil setiap segmen sebagai dasar pengambilan kebijakan stok yang objektif. Rincian profil klaster untuk variabel kondisi, odometer, dan harga jual dipaparkan secara mendalam dalam Tabel 2. Rata-rata Variabel Per Klaster (Centroid).

Tabel 2. Rata-rata Variabel Per Klaster (*Centroid*)

Klaster	<i>Condition</i> (Avg)	<i>Odometer</i> (Avg)	<i>Selling Price</i> (Avg)
Klaster 0	37,7	46.860,9	\$13.456,26
Klaster 1	18,56	113.468,43	\$6.526,08
Klaster 2	36,07	28.603,61	\$29.658,94

Berdasarkan hasil komputasi pada Tabel 2. Rata-rata Variabel Per Klaster (*Centroid*). mengungkap profil yang sangat kontras antar kelompok, yang menjadi dasar objektif bagi pengambilan keputusan manajerial dalam siklus manajemen pengetahuan.

3.2.1 Klaster 0 (Medium - Market Stock)

Kelompok ini mewakili stok kelas menengah dengan harga rata-rata \$13.456,26. Meskipun secara statistik memiliki rata-rata kondisi fisik tertinggi (37,7), namun jarak tempuhnya sudah mencapai 46.860,9. Hal ini menandakan unit dalam klaster ini adalah aset yang sangat likuid namun berada pada fase awal penyusutan nilai, sehingga memerlukan strategi perputaran stok (*inventory turnover*) yang stabil.

Secara operasional, kendaraan dalam kategori ini masih memiliki daya tarik pasar yang cukup baik dan cenderung lebih mudah dipasarkan dibandingkan kendaraan dengan jarak tempuh sangat tinggi. Dalam praktik optimasi *inventory modern*, kelompok seperti ini sering dijadikan penopang arus kas karena memiliki keseimbangan antara harga, kondisi, dan minat pasar.

Pengelolaan yang efektif terhadap klaster ini dapat dilakukan melalui pemantauan rotasi penjualan, evaluasi tren permintaan, serta penyesuaian strategi promosi ringan tanpa harus mengorbankan margin keuntungan secara signifikan. Dengan demikian, klaster ini berperan sebagai stabilisator struktur *inventory* perusahaan. Penelitian terdahulu mengonfirmasi bahwa kategori menengah dalam klastering inventori berfungsi sebagai penyeimbang antara risiko biaya penyimpanan dan potensi pendapatan [24].

3.2.2 Klaster 1 (High-Risk/Liquidation Stock)

Klaster ini memiliki karakteristik paling berisiko dengan jarak tempuh tertinggi mencapai 113.468,43 dan harga jual terendah sebesar \$6.526,08. Rendahnya kondisi fisik (18,56) memberikan sinyal objektif bahwa unit dalam Klaster 1 memiliki risiko biaya penyimpanan (*holding cost*) yang tinggi.

Dalam perspektif manajemen rantai suplai dan pengendalian *inventory*, stok dengan karakteristik seperti ini berpotensi meningkatkan beban operasional jika tidak segera direspons. Oleh karena itu, strategi percepatan likuidasi menjadi prioritas, misalnya melalui diskon, promosi terbatas, atau strategi bundling penjualan.

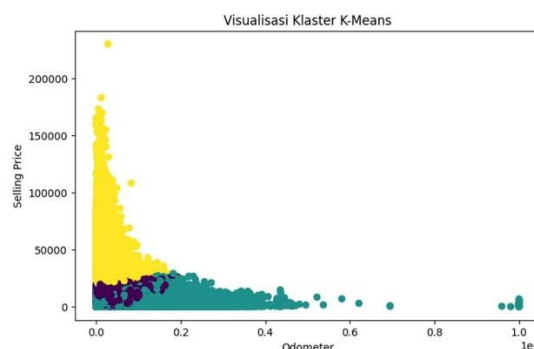
Segmentasi ini juga menunjukkan bagaimana data mining dapat membantu manajemen dalam mengidentifikasi stok lambat (*slow-moving stock*) secara lebih cepat dan akurat. Tanpa pendekatan berbasis klaster, kendaraan berisiko tinggi dapat bercampur dengan stok lain dan sulit diidentifikasi secara sistematis. Penggunaan algoritma K-Means terbukti efektif dalam memisahkan stok dengan risiko tinggi agar manajemen dapat segera mengambil tindakan likuidasi untuk menghindari kerugian yang lebih besar [25].

3.2.3 Klaster 2 (High-Value Asset)

Klaster ini merupakan kelompok kendaraan premium dengan jarak tempuh terendah (28.603,61) dan harga jual tertinggi mencapai rata-rata \$29.658,94. Meskipun kondisi fisiknya berada pada angka 36,07, nilai ekonominya yang tinggi menjadikan klaster ini sebagai aset strategis perusahaan.

Dalam praktik optimasi *inventory global*, aset bernilai tinggi memerlukan pendekatan berbeda dibandingkan stok reguler. Fokus utama tidak hanya pada kecepatan perputaran, tetapi juga pada perlindungan nilai aset, pemeliharaan kualitas, dan strategi pemasaran yang tepat sasaran.

Pengelolaan klaster ini juga memiliki implikasi terhadap citra perusahaan. Kendaraan premium yang dikelola dengan baik dapat meningkatkan persepsi kualitas *inventory* secara keseluruhan dan memperkuat posisi kompetitif perusahaan di pasar. Karakteristik klaster dengan harga tinggi dan stok terbatas ini memerlukan pendekatan manajemen persediaan yang lebih spesifik guna menjaga ketersediaan unit premium tanpa membebani biaya modal [8].



Gambar 3. Visualisasi Sebaran Klaster dalam Ruang 3D

Visualisasi pada Gambar 3 memberikan konfirmasi visual yang kuat terhadap efektivitas pengelompokan secara spasial. Pemisahan yang terlihat jelas antar warna kluster dalam ruang tiga dimensi (Kondisi, Odometer, Harga) membuktikan bahwa parameter eksperimen telah bekerja secara akurat. Jarak yang signifikan antar *centroid* kluster menunjukkan bahwa model berhasil meminimalkan variasi di dalam kelompok (*intra-cluster*) sekaligus memaksimalkan perbedaan antar kelompok (*inter-cluster*). Hal ini memperkuat validitas hasil penelitian bahwa segmentasi ini bukan sekadar pengelompokan acak, melainkan representasi nyata dari struktur pasar kendaraan yang ada, sehingga layak dijadikan landasan Standar Operasional Prosedur (SOP) manajemen inventori berbasis data.

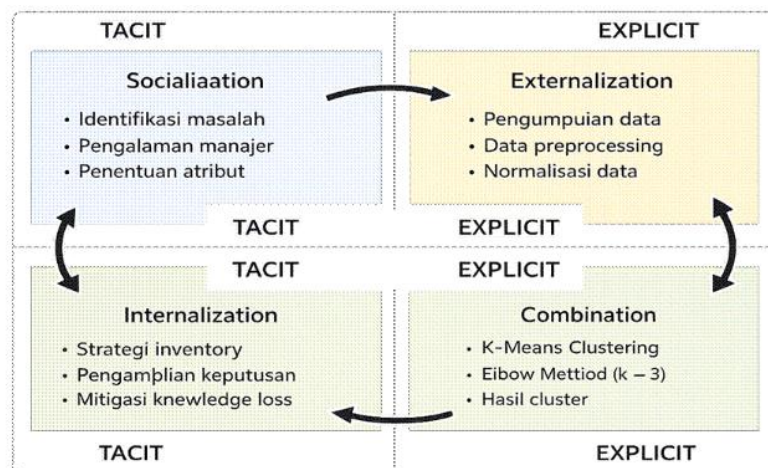
3.3 Integrasi Framework SECI dalam Sistem Optimasi Inventory Industri Otomotif

Optimasi strategi inventory dalam industri otomotif saat ini memerlukan sinergi mendalam antara analisis data kuantitatif dan pengelolaan pengetahuan organisasi yang terstruktur. Hasil klusterisasi K-Means terhadap 558.837 data Vehicle Sales diintegrasikan dengan model SECI (*Socialization, Externalization, Combination, Internalization*) untuk memastikan bahwa temuan analitik tidak hanya menjadi angka statis, melainkan bertransformasi menjadi sistem pengetahuan berkelanjutan.

Integrasi ini bertujuan agar segmentasi seperti *Medium-Market Stock, High-Risk/Liquidation Stock, dan High-Value Asset* dapat dijadikan pedoman operasional yang konsisten. Optimalisasi ini mempertegas bahwa manajemen pengetahuan modern merupakan kunci utama dalam mempertahankan keunggulan kompetitif melalui inovasi yang terdokumentasi dan sistematis [9].

- Tahap *Socialization*: Tahap ini melibatkan transfer pengetahuan tacit melalui interaksi sosial dan diskusi manajerial terhadap karakteristik tiga kluster ($k=3$) yang ditemukan. Diskusi ini sangat krusial untuk mentransfer pengalaman intuitif manajer terkait risiko *holding cost*, pola perputaran stok, serta strategi penetapan harga yang tidak sepenuhnya tertangkap oleh algoritma. Interaksi ini membantu memperkuat kesamaan persepsi dalam pengambilan keputusan strategis, sebagaimana ditekankan dalam tinjauan mengenai efektivitas model SECI pada organisasi modern [12].
- Tahap *Externalization*: Pengetahuan tacit tersebut kemudian diformalisasikan menjadi format eksplisit dengan mengubah hasil centroid variabel *Condition, Odometer, dan Selling Price* menjadi pedoman evaluasi inventory berbasis data. Karakteristik stok didokumentasikan sebagai standar klasifikasi formal atau SOP guna mengurangi subjektivitas dan memitigasi risiko *knowledge loss*. Penerapan model SECI sebagai sistem berbagi pengetahuan mampu meningkatkan standarisasi keputusan organisasi secara signifikan [16].
- Tahap *Combination*: Pada tahap ini, model K-Means diintegrasikan secara sistematis ke dalam basis data inventaris dan *Decision Support System (DSS)*. Proses ini melibatkan penggunaan parameter yang telah dinormalisasi melalui *StandardScaler* dan inialisasi *k-means++*. Penggabungan pengetahuan eksplisit baru dengan infrastruktur TI ini terbukti meningkatkan efisiensi operasional dan akurasi distribusi dalam manajemen rantai pasok otomotif [1]. Selain itu, algoritma klustering membantu penentuan alokasi stok yang lebih presisi pada lokasi logistik kendaraan [7].
- Tahap *Internalization*: Tahap akhir diwujudkan melalui adopsi strategi inventory berbasis kluster ke dalam praktik operasional harian. Strategi likuidasi cepat untuk Klaster 1 dan pengelolaan aset premium untuk Klaster 2 menjadi kompetensi praktis yang tertanam dalam organisasi. Melalui praktik nyata ini, karyawan menyerap kembali pengetahuan eksplisit tersebut menjadi kompetensi tacit baru, yang secara kolektif memperkuat retensi pengetahuan dan mendorong kinerja organisasi secara keseluruhan [11].

Implementasi model SECI dalam penelitian ini secara langsung memitigasi risiko hilangnya pengetahuan akibat tingginya perputaran karyawan di industri otomotif. Dengan mentransformasikan hasil analitik menjadi aset digital yang permanen, organisasi mampu menjaga kontinuitas strategi bisnis dalam menghadapi dinamika pasar yang kompleks. Visualisasi mengenai bagaimana integrasi data tersebut mendukung proses pengambilan keputusan diuraikan pada Gambar 4 berikut ini.



Gambar 4. Integrasi Model SECI dalam Optimasi Strategi Inventory dan Mitigasi Knowledge Loss

Berdasarkan visualisasi pada Gambar 4 bahwa pengetahuan baru tercipta melalui proses sintesis antara hasil pengolahan data transaksi dan kebijakan inventori yang sudah ada sebelumnya. Hal ini memungkinkan perusahaan untuk memiliki panduan operasional yang lebih dinamis, di mana data statistik dari K-Means menjadi fondasi utama dalam merumuskan strategi pemasaran dan pengelolaan stok yang lebih akurat guna memitigasi risiko kerugian akibat kesalahan estimasi stok [21]. Melalui tahap ini, temuan analitik tidak lagi berdiri sebagai angka mentah, melainkan telah bertransformasi menjadi modal intelektual organisasi yang terdokumentasi secara sistematis.

3.4 Implementasi K-Means Clustering dalam Mitigasi Knowledge Loss

Penerapan *Elbow Method* dalam analisis menunjukkan bahwa jumlah kluster yang paling optimal adalah $k=3$. Segmentasi ini menghasilkan tiga profil *inventory* yang berbeda, yaitu Klaster 0 (*Medium-Market Stock*), Klaster 1 (*High-Risk/Liquidation Stock*), dan Klaster 2 (*High-Value Asset*). Karakteristik *centroid* menunjukkan bahwa Klaster 1 memiliki rata-rata jarak tempuh tertinggi dan harga jual terendah, sehingga memerlukan strategi likuidasi cepat untuk menghindari peningkatan biaya penyimpanan dan depresiasi lanjutan. Penggunaan algoritma klustering dalam logistik kendaraan seperti ini terbukti membantu dalam penentuan alokasi stok yang lebih presisi [7]. Sebaliknya, Klaster 2 memiliki nilai jual tertinggi dengan jarak tempuh lebih rendah, sehingga memerlukan pengelolaan sebagai aset bernilai tinggi yang harus dijaga kualitas dan stabilitas marginnya. Sementara itu, Klaster 0 berada pada posisi menengah dan berfungsi sebagai penyeimbang arus kas melalui rotasi penjualan yang relatif stabil.

Integrasi hasil kluster ke dalam *framework* SECI memungkinkan terjadinya dokumentasi dan standarisasi keputusan *inventory* berbasis data. Strategi seperti percepatan penjualan untuk stok berisiko tinggi, stabilisasi perputaran untuk stok menengah, serta pengamanan nilai aset premium menjadi pedoman operasional yang terdokumentasi secara sistematis. Pendekatan ini mengurangi ketergantungan pada intuisi individu dan meningkatkan objektivitas pengambilan keputusan karena seluruh kategori stok telah memiliki dasar klasifikasi yang terukur. Penerapan model SECI dalam sistem digital perusahaan terbukti mampu meningkatkan standarisasi keputusan serta distribusi pengetahuan secara lebih merata [16].

Penelitian ini mengindikasikan bahwa penerapan algoritma K-Means yang terintegrasi dengan *framework* SECI tidak hanya memberikan peningkatan akurasi segmentasi *inventory* secara kuantitatif, tetapi juga membentuk mekanisme retensi pengetahuan yang sistematis dalam organisasi. Melalui proses konversi pengetahuan dari *tacit* menjadi *explicit*, pengalaman operasional yang sebelumnya tersimpan secara individual kini terdokumentasi dalam bentuk kategori kluster dan laporan analitis. Proses konversi ini secara kolektif memperkuat retensi pengetahuan organisasi dan mendorong kinerja inovasi secara keseluruhan [11]. Dengan demikian, organisasi memiliki referensi historis yang dapat digunakan kembali dalam pengambilan keputusan berikutnya.

Selain itu, implikasi kuantitatif dari distribusi masing-masing kluster berpengaruh langsung terhadap efisiensi operasional perusahaan. Proporsi kendaraan dalam setiap kelompok menunjukkan pola distribusi risiko yang memengaruhi strategi alokasi sumber daya. Optimasi strategi *inventory* melalui integrasi data analitik seperti ini terbukti mampu meningkatkan efisiensi operasional dan akurasi distribusi dalam manajemen rantai pasok manufaktur [1]. Klaster dengan harga rendah dan jarak tempuh tinggi berpotensi meningkatkan *holding cost* apabila tidak segera diproses melalui strategi promosi khusus, sementara klaster bernilai tinggi memerlukan pengelolaan risiko penyimpanan yang lebih selektif.

Pendekatan berbasis data ini juga menciptakan konsistensi dalam proses pengambilan keputusan. Dalam volume transaksi yang besar, keputusan manual cenderung rentan terhadap bias subjektif dan inkonsistensi antar periode. Dengan adanya sistem *clustering*, evaluasi *inventory* dapat dilakukan secara periodik dengan parameter yang sama sehingga menghasilkan stabilitas dalam rotasi stok. Hal ini sejalan dengan prinsip manajemen pengetahuan modern yang menjadi kunci utama dalam mempertahankan keunggulan kompetitif melalui inovasi yang terdokumentasi dan sistematis [9].

Dari perspektif akademik, penelitian ini memperlihatkan kontribusi integratif antara teknik *unsupervised learning* dan model konversi pengetahuan organisasi. Integrasi ini menunjukkan bahwa analitik data tidak hanya berfungsi sebagai alat klasifikasi numerik, tetapi juga sebagai mekanisme pendukung retensi pengetahuan dan penguatan tata kelola *inventory*. Penerapan model SECI terbukti memiliki peran krusial dalam meningkatkan efektivitas pengambilan keputusan pada berbagai organisasi modern [12]. Dengan demikian, model yang dihasilkan bersifat aplikatif secara manajerial sekaligus relevan secara konseptual.

Dari sisi strategis, model ini dapat digunakan sebagai acuan dalam pengembangan sistem pendukung keputusan berbasis kluster sehingga memungkinkan manajemen memantau pergerakan stok secara lebih terstruktur. Implementasi lanjutan dapat berupa visualisasi *dashboard* yang menampilkan distribusi kluster secara berkala, sehingga perusahaan dapat merespons perubahan pasar dengan lebih cepat dan adaptif.

4. KESIMPULAN

Penerapan K-Means Clustering berhasil mengidentifikasi tiga cluster utama yaitu medium market stock, liquidation stock dan high value asset yang secara jelas merepresentasikan perbedaan karakteristik berdasarkan variabel *condition*, *odometer*, dan *selling price* sehingga memungkinkan penentuan prioritas strategi *inventory* yang lebih terarah dan objektif. Temuan ini menegaskan bahwa pendekatan berbasis data mampu menggantikan ketergantungan pada intuisi dengan klasifikasi yang konsisten untuk mendukung percepatan likuidasi, stabilisasi perputaran stok dan perlindungan

aset bernilai tinggi. Integrasi dengan model SECI memperkuat kontribusi penelitian dengan mentransformasikan hasil analitik menjadi pengetahuan organisasi yang terstruktur melalui proses *socialization*, *externalization*, *combination*, dan *internalization* sehingga memastikan keberlanjutan waasan strategis. Secara keseluruhan, kombinasi K-Means dan SECI memberikan kontribusi signifikan dalam membangun strategi inventory yang terukur sekaligus memitigasi risiko *knowledge loss* yang dapat meningkatkan kontinuitas pengetahuan dan daya saing organisasi dalam menghadapi dinamika pasar.

REFERENCES

- [1] S. M. Abdullah, "Inventory Optimization in Global Automotive Manufacturing Supply Chains," *J. Procure. Supply Chain Manag.*, vol. 4, no. 1, pp. 48–59, Jul. 2025, doi: 10.58425/jpsc.v4i1.377.
- [2] N. Nurahman and J. Susanto, "Klasterisasi Data Penerima Bantuan Langsung Tunai Menggunakan Algoritma K-Means," *JURIKOM (Jurnal Ris. Komputer)*, vol. 10, no. 2, p. 461, Apr. 2023, doi: 10.30865/jurikom.v10i2.5807.
- [3] A. A. Dermawan, A. Lawi, D. A. Putera, D. E. Kurniawan, K. K. Ummatin, and J. Steve, "Optimizing Inventory Management: Data-Driven Insights from K-Means Clustering Analysis of Prescription Patterns," *Sci. J. Informatics*, vol. 11, no. 3, pp. 811–820, Oct. 2024, doi: 10.15294/sji.v11i3.8690.
- [4] M. D. Akhda and K. D. Tania, "Comparison of K-Means and K-Medoids Algorithms for Clustering Poverty Data in South Sumatra Using DBI Evaluation," *Digit. Zo. J. Teknol. Inf. dan Komun.*, vol. 15, no. 2, pp. 233–245, Nov. 2024, doi: 10.31849/digitalzone.v15i2.23624.
- [5] E. T. Lakesiyah, K. D. Tania, and M. Afrina, "Komparasi Klasterisasi Data Historis Gempa Bumi Menggunakan DBSCAN, K-Means, dan Agglomerative Clustering," vol. 7, no. 3, pp. 1674–1683, 2025, doi: 10.47065/bits.v7i3.8426.
- [6] M. M. Triputra, A. Rifai, and K. D. Tania, "Evaluasi Kualitas Pendidikan Dasar di Sumatera Selatan Menggunakan Business Intelligence Model," *J. Pendidik. dan Teknol. Indones.*, vol. 5, no. 3, pp. 601–613, Mar. 2025, doi: 10.52436/1.jpti.618.
- [7] S. Cheng, X. Zhang, and J. Wang, "Research on Vehicle Logistics Location Allocation Strategy Based on K-Means Clustering," *Acad. J. Bus. Manag.*, vol. 7, no. 9, 2025, doi: 10.25236/AJBM.2025.070909.
- [8] S. Melisa, S. Defit, and R. Sovia, "Penerapan Algoritma K-Means Clustering untuk Optimalisasi Persediaan Liquid Vape Berdasarkan Data Penjualan," *J. KomtekInfo*, pp. 38–45, Mar. 2025, doi: 10.35134/komtekinfo.v12i1.620.
- [9] F. M. AlQhtani, "Knowledge Management for Research Innovation in Universities for Sustainable Development: A Qualitative Approach," *Sustainability*, vol. 17, no. 6, p. 2481, Mar. 2025, doi: 10.3390/su17062481.
- [10] Sugianto, R. Firdaus, Suhardi, and M. Amin, "The impact of employee turnover on operational efficiency, innovation, and customer satisfaction: the mediation role of tacit knowledge loss," *Int. J. Enterp. Model.*, vol. 19, no. 1, pp. 56–66, 2025.
- [11] 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.
- [12] R. R. Ritonga, Y. Ernanda, and S. Simbolon, "Integrating Knowledge Management and Change: Exploring SECI Model Applications in SMEs and Modern Organizations," *Bisnis-Net J. Ekon. dan Bisnis*, vol. 7, no. 2, pp. 927–931, Dec. 2024, doi: 10.46576/bn.v7i2.5534.
- [13] F. Fkih, D. Rhouma, and M. N. Omri, "DemogCF model of personalized recommendations based on demographic characteristics for overcoming data sparsity and cold start problems," *Int. J. Inf. Technol.*, vol. 17, no. 1, pp. 169–177, Jan. 2025, doi: 10.1007/s41870-024-02316-9.
- [14] Gartner, "Definition of Knowledge Management (KM)," Gartner Information Technology Glossary. Accessed: Feb. 20, 2026. [Online]. Available: <https://www.gartner.com/en/information-technology/glossary/km-knowledge-management>
- [15] C. Bratianu, M. Handzic, E. Bolisani, and B. Eds, *The Future of Knowledge Management*. Springer, 2023.
- [16] R. Rosdiyanto, I. Imelda, and T. Tjahjanto, "Knowledge Management System dengan SECI Model sebagai Sharing Knowledge Perusahaan Software Developer PT. XYZ," *J. Eksplora Inform.*, vol. 14, no. 1, pp. 12–22, 2024, doi: 10.30864/eksplora.v14i1.1045.
- [17] S. A. Fahmi, A. Ikhwan, and F. H. Sibarani, "Implementasi Data Mining Dengan Menggunakan Metode K-Means Clustering Untuk Menentukan Penjualan Sparepart Mobil," *J. Komput. Teknol. Inf. Sist. Inf.*, vol. 4, no. 1, pp. 204–209, 2025, doi: 10.62712/juktisi.v4i1.388.
- [18] J. Han, J. Pei, and H. Tong, *Data Mining: Concepts and Techniques*, 4th ed. Waltham, MA: Elsevier (Morgan Kaufmann), 2023. doi: 10.1016/C2013-0-18660-6.
- [19] A. Yahya and R. Kurniawan, "Implementasi Algoritma K-Means untuk Pengelompokan Data Penjualan Berdasarkan Pola Penjualan," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 1, pp. 350–358, Jan. 2025, doi: 10.57152/malcom.v5i1.1773.
- [20] Scikit-learn developers, "sklearn.preprocessing.StandardScaler," scikit-learn.org. Accessed: Feb. 20, 2026. [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>
- [21] I. Herdiana, M. A. Kamal, Triyani, M. N. Estri, and Renny, "A more precise elbow method for optimum k-means clustering," pp. 1–22, 2025, doi: 10.48550/arXiv.2502.00851.
- [22] B. Chassagnol *et al.*, "Gaussian Mixture Models in R," vol. 15, no. June, pp. 56–76, 2023.
- [23] R. R. Pakpahan, "Penerapan Metode Clustering Dengan Algoritma K-Means Untuk Menganalisa Data Film Lokal (Indonesia) Populer," *JURIKOM (Jurnal Ris. Komputer)*, vol. 12, no. 1, pp. 26–33, Mar. 2025, doi: 10.30865/jurikom.v12i1.8490.
- [24] S. Abdy, E. R. Br Gultom, S. Ramadhany, and A. Afifudin, "Prediksi Penjualan Sparepart Mobil Terlaris Menggunakan Metode K-Nearest Neighbor," *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 6, p. 2003, Dec. 2022, doi: 10.30865/jurikom.v9i6.5189.
- [25] S. Chaerani, R. A. Yusda, and Rohminatin, "Implementation of the K-Means Algorithm for Clustering Hot Selling and Less Selling Goods at XYZ Wholesalers," *JURIKOM (Jurnal Ris. Komputer)*, vol. 12, no. 4, pp. 602–609, 2025, doi: 10.30865/jurikom.v12i4.8882.