

Klasterisasi Penggunaan Ban dengan *Cost Per Kilometer* Terendah pada PT. PL menggunakan Metode K-Means

Muhammad Syani ¹, Tundo ^{2*}, Sugiyono ³, Tri Wahyudi ⁴

^{1,2*,3,4} Program Studi Sistem Informasi, Sekolah Tinggi Ilmu Komputer Cipta Karya Informatika, Kota Jakarta Timur, Daerah Khusus Ibukota Jakarta, Indonesia.

Email: muhammad.syani94@gmail.com ¹, asna8mujahid@gmail.com ^{2*}, inosoguy007@gmail.com ³, triwahyudi199003@gmail.com ⁴

Histori Artikel:

Dikirim 26 Juli 2024; *Diterima dalam bentuk revisi* 8 Agustus 2024; *Diterima* 15 Agustus 2024; *Diterbitkan* 20 September 2024. Semua hak dilindungi oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) STMKI Indonesia Banda Aceh.

Abstrak

PT. Puninar Logistics, yang didirikan pada tahun 1969, telah berkembang menjadi salah satu perusahaan logistik terkemuka di Indonesia. Perusahaan ini menawarkan solusi logistik yang mencakup manajemen material, manufaktur, pergudangan, distribusi, bea cukai, pengiriman barang, dan layanan pasca pengiriman melalui berbagai anak perusahaannya. Setelah bahan bakar, pengeluaran terbesar kedua perusahaan adalah untuk ban. Pengelolaan ban yang tepat dapat mengurangi biaya perawatan dan merupakan salah satu strategi efisiensi biaya dalam industri logistik. Penelitian ini menggunakan teknik data mining dengan metode K-means untuk menganalisis dan mengklasifikasikan ban berdasarkan jarak tempuh dan biaya per kilometer terendah, dengan tujuan memantau pengeluaran bulanan per kilometer. PT. Puninar menghabiskan sekitar dua miliar rupiah per bulan untuk kebutuhan stok ban, mengingat perusahaan memiliki lebih dari tujuh ratus truk. Saat ini, PT. Puninar menggunakan berbagai jenis ban, termasuk Bridgestone, Doublecoin, Effiplus, Chengsang, dan merek lainnya yang memiliki daya tahan bervariasi.

Kata Kunci: Pemakaian Ban; Biaya per Kilometer; K-Means.

Abstract

Established in 1969, PT. Puninar has grown to become one of Indonesia's leading logistics companies. The company provides a broad range of logistics solutions through its subsidiaries, encompassing material management, manufacturing, warehousing, distribution, customs services, freight forwarding, and post-delivery operations. After fuel, tires represent the second-largest expenditure for the company. Proper tire management can reduce maintenance costs, making it a key cost-reduction strategy in the logistics sector. This study utilizes data mining techniques, specifically the K-means method, to analyze and classify tires based on travel distance and the lowest cost per kilometer, enabling monthly cost monitoring. PT. Puninar allocates approximately two billion rupiah per month for tire inventory due to its fleet of over seven hundred trucks. The company currently employs various tire brands, including Bridgestone, Doublecoin, Effiplus, Chengsang, and others, with varying levels of durability.

Keyword: Tire Usage; Cost per Kilometer; K-Means.

1. Pendahuluan

PT. Puninar Logistics, yang berdiri sejak tahun 1969, telah berkembang menjadi salah satu perusahaan logistik terkemuka di Indonesia. Dengan pengalaman lebih dari lima dekade, Puninar telah menyediakan berbagai solusi logistik melalui anak perusahaan yang beroperasi di berbagai sektor, termasuk manajemen material, manufaktur, pergudangan, distribusi, bea cukai, transportasi, serta pelacakan. Perusahaan ini terus memperluas operasi bisnisnya ke berbagai kota besar di Indonesia, seperti Jakarta, Bandung, Semarang, Surabaya, Palembang, Medan, Banjarmasin, dan Balikpapan. Puninar juga terus meningkatkan efisiensi operasional dengan membangun kemitraan strategis untuk memperluas jaringan logistiknya, baik di dalam maupun luar negeri.

Salah satu tantangan utama yang dihadapi PT. Puninar adalah pengelolaan biaya operasional yang efektif, khususnya terkait pengeluaran untuk ban yang digunakan dalam armada truknya. Ban menjadi pengeluaran terbesar kedua setelah bahan bakar, sehingga strategi untuk mengelola dan menekan biaya ini sangat diperlukan. PT. Puninar telah mengimplementasikan sistem manajemen ban atau *Tire Management System* (TMS), yang berfungsi untuk memantau dan mengelola penggunaan ban dengan lebih efisien. Penggunaan ban yang tidak tepat dapat menyebabkan peningkatan biaya perawatan dan berkurangnya efisiensi dalam operasional transportasi.

Untuk mengurangi biaya terkait penggunaan ban, PT. Puninar juga mengimpor ban dari berbagai negara, termasuk Cina, Thailand, dan Vietnam, yang dikenal menawarkan harga yang lebih kompetitif. Meskipun begitu, tetap diperlukan analisis yang mendalam untuk memastikan bahwa ban impor tersebut memenuhi standar kualitas dan daya tahan yang sesuai dengan kebutuhan operasional. Salah satu metode yang digunakan dalam analisis ini adalah metode *K-means clustering*, yang dapat mengelompokkan ban berdasarkan biaya per kilometer (CPK), ukuran, dan daya tahan. CPK adalah metrik penting yang digunakan untuk mengukur efisiensi penggunaan ban, dengan cara membagi harga total ban dengan jarak tempuhnya. Ban yang memiliki CPK lebih rendah dinilai lebih efisien dalam hal biaya penggunaan.

Algoritma K-Means telah banyak digunakan dalam berbagai bidang penelitian untuk mengelompokkan data berdasarkan karakteristik tertentu. Misalnya, Nurdian dan Anwar (2018) menggunakan metode ini untuk pengambilan keputusan dalam pengelolaan data, sementara Ariyanto (2022) memanfaatkan algoritma ini untuk mengklasifikasi data medis. Pada manajemen logistik, metode K-Means terbukti dapat membantu mengidentifikasi pola pengelompokan yang efisien untuk pemilihan ban berdasarkan kriteria seperti harga dan daya tahan. Beberapa penelitian yang relevan juga menunjukkan bahwa algoritma ini efektif dalam membantu perusahaan mengoptimalkan keputusan terkait pengelolaan aset dan biaya operasional (Somantri *et al.*, 2016; Fitri *et al.*, 2023; Priyatman *et al.*, 2019).


Dalam penelitian ini, metode K-Means akan digunakan untuk mengelompokkan data terkait penggunaan ban di PT. Puninar berdasarkan beberapa parameter, termasuk biaya, ukuran, dan jarak tempuh. Proses klusterisasi ini diharapkan dapat memberikan panduan yang lebih jelas dalam memilih ban yang paling efisien dari segi biaya dan performa. PT. Puninar, dengan armada lebih dari tujuh ratus truk, mengeluarkan sekitar dua miliar rupiah setiap bulannya untuk pengadaan ban. Oleh karena itu, penelitian ini bertujuan untuk memberikan rekomendasi tentang ban yang menawarkan CPK terendah, yang pada akhirnya dapat menurunkan biaya operasional perusahaan. Studi ini juga diharapkan memberikan hasil yang dapat diadopsi oleh perusahaan lain di sektor logistik, yang menghadapi tantangan serupa dalam pengelolaan komponen transportasi mereka. Dengan memanfaatkan metode K-Means, PT. Puninar dapat membuat keputusan yang lebih terukur terkait pengadaan ban, serta meningkatkan efisiensi penggunaan ban dalam jangka panjang.

2. Metode Penelitian

Metode penelitian yang digunakan dalam studi ini dijelaskan secara sistematis agar dapat mempermudah pemahaman dan pemantauan perkembangan penelitian. Tujuan dari metodologi ini adalah untuk menciptakan proses yang teratur dan terstruktur sehingga hasil penelitian dapat dinilai secara objektif dan akurat.

2.1 Data Penelitian


Penelitian ini menggunakan data dari PT. Puninar Logistics, khususnya dari departemen Fleet Maintenance (Workshop) bagian Tire Management System. Langkah-langkah penelitian meliputi pengumpulan data pemakaian ban berdasarkan merek dan ukuran, klusterisasi menggunakan metode K-means, dan evaluasi hasil untuk menentukan biaya per kilometer terendah. Lokasi PT. Puninar Logistics berada di Jl. Komp. PT. Puninar No.8, RT.8/RW.3, Cilincing, Jakarta Utara, 14130.



Gambar 1. Lokasi Penelitian

2.2 Penerapan Metodologi


Metode k-means adalah salah satu algoritma *clustering* atau pengelompokan data yang populer dalam data mining. Tujuan dari metode k-means adalah untuk mengelompokkan data menjadi beberapa kelompok (*cluster*) berdasarkan kesamaan fitur yang dimiliki oleh data dalam setiap kelompok. Metode yang di gunakan dalam penelitian ini adalah metode K-Means yang terdiri beberapa tahap seperti berikut.



Gambar 2. Alur penelitian

Penelitian dilakukan melalui beberapa tahapan yang bertujuan untuk menghasilkan analisis yang sistematis dan akurat. Langkah pertama adalah identifikasi masalah, yang merupakan fondasi dari seluruh proses penelitian. PT. Puninar Logistics menghadapi tantangan besar dalam hal pengeluaran operasional yang signifikan, terutama terkait dengan penggunaan ban pada armada truknya. Biaya untuk ban merupakan komponen pengeluaran terbesar kedua setelah bahan bakar. Oleh karena itu, perusahaan membutuhkan strategi yang efektif untuk mengurangi biaya ini, terutama melalui pemilihan ban yang paling efisien berdasarkan biaya per kilometer (CPK). Hal ini menjadi titik awal penelitian untuk memahami bagaimana metode analisis dapat membantu mengidentifikasi ban dengan CPK terendah. Langkah kedua dalam penelitian ini adalah pengumpulan data. Data diperoleh dari Departemen Fleet Maintenance PT. Puninar, khususnya melalui sistem Tire Management System (TMS) yang digunakan perusahaan. Data ini mencakup berbagai informasi penting mengenai pemakaian ban, seperti merek ban, ukuran, jarak tempuh, dan CPK. Semua data yang terkumpul

tersebut kemudian dipersiapkan untuk analisis lebih lanjut. Proses pengumpulan data ini sangat penting karena kualitas data yang diperoleh akan menentukan keakuratan hasil analisis selanjutnya. Langkah ketiga adalah analisis data menggunakan metode *K-means clustering*. *K-means* adalah salah satu algoritma pengelompokan data yang umum digunakan dalam analisis *data mining*. Dalam penelitian ini, metode ini digunakan untuk mengklasifikasikan ban berdasarkan atribut seperti CPK, ukuran, dan daya tahan. Hasil dari proses klasterisasi ini akan menunjukkan kelompok ban dengan efisiensi tertinggi, yang diukur melalui nilai CPK. Melalui proses ini, PT. Puninar dapat lebih mudah menentukan ban mana yang memiliki biaya operasional paling rendah, sekaligus memastikan bahwa ban yang dipilih memiliki kinerja optimal. Untuk mengelola seluruh proses penelitian, digunakan metodologi CRISP-DM (Cross-Industry Standard Process for Data Mining). CRISP-DM adalah kerangka kerja standar yang dirancang untuk memberikan panduan dalam siklus hidup proyek *data mining*. Metode ini dikembangkan oleh Daimler-Chrysler, SPSS, dan NCR, dan telah diterapkan di berbagai industri untuk menyelesaikan masalah berbasis data. Kerangka kerja CRISP-DM terdiri dari enam tahap: pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan penerapan hasil. Tahap pertama dari CRISP-DM, pemahaman bisnis, berfokus pada identifikasi masalah bisnis utama yang dihadapi oleh PT. Puninar, yaitu tingginya biaya penggunaan ban. Tahap ini membantu menentukan bagaimana solusi data mining dapat digunakan untuk mengatasi masalah tersebut. Tahap kedua adalah pemahaman data, yang mencakup pengumpulan dan pemrosesan data terkait pemakaian ban. Setelah data terkumpul, tahap persiapan data dilakukan, di mana data disaring dan disiapkan untuk analisis menggunakan pivot table guna memastikan bahwa data relevan dan sesuai dengan kebutuhan analisis. Tahap pemodelan menggunakan algoritma *K-means* diterapkan pada data yang sudah dipersiapkan untuk mengelompokkan ban berdasarkan nilai CPK dan atribut lainnya. Pemodelan ini dilakukan menggunakan perangkat lunak RapidMiner, yang memungkinkan visualisasi hasil klasterisasi. Setelah model dibuat, hasilnya dievaluasi untuk memastikan bahwa cluster yang terbentuk sesuai dengan tujuan penelitian, yaitu mengidentifikasi ban dengan CPK terendah. Tahap evaluasi sangat penting untuk memastikan keakuratan model yang dihasilkan. Tahap akhir dalam metodologi CRISP-DM adalah penerapan hasil. Pada tahap ini, hasil analisis digunakan untuk memberikan rekomendasi yang dapat diimplementasikan oleh PT. Puninar. Rekomendasi ini diharapkan dapat membantu perusahaan dalam mengurangi biaya operasional melalui penggunaan ban yang lebih efisien. Dengan menerapkan hasil dari model *K-means*, PT. Puninar dapat mengoptimalkan penggunaan ban berdasarkan analisis yang sistematis, yang pada akhirnya berkontribusi terhadap peningkatan efisiensi operasional perusahaan. Gambar 3 berikut ini menggambarkan proses CRISP-DM yang digunakan dalam penelitian ini untuk memfasilitasi setiap tahapan dalam analisis data.



Gambar 3. Proses CRISP-DM

Proses pengumpulan data pada penelitian ini akan mengambil data dari sebuah Perusahaan PT. Puninar di Departemen Fleet Maintenance (*Workshop*), yaitu data pelepasan ban yang diambil tahun 2023. Metodologi penelitian ini dimulai dengan analisis pivot table untuk menyaring data relevan,

seperti merk ban, ukuran, tyre distance, dan cost per kilometer (CPK). Data yang telah diolah melalui pivot table kemudian diterapkan pada metode *clustering* K-Means menggunakan RapidMiner, untuk mengelompokkan ban berdasarkan CPK. Langkah-langkah yang dilakukan meliputi identifikasi masalah, studi literatur, pengumpulan data, preprocessing, dan implementasi K-Means. Setelah data dianalisis, penarikan kesimpulan diambil untuk menentukan ban dengan CPK terendah, yang diharapkan dapat memberikan rekomendasi dan saran untuk penelitian selanjutnya. Rancangan pengujian dilakukan untuk memastikan keakuratan dan efektivitas metode yang diterapkan.

3. Hasil dan Pembahasan


3.1 Hasil

3.1.1 Alat Penelitian

Alat dan bahan penelitian ini meliputi Microsoft Excel untuk mengumpulkan dan memproses data, seperti merk ban, ukuran, tyre distance, dan cost per kilometer (CPK) menggunakan pivot table. RapidMiner Studio digunakan untuk menerapkan metode K-Means dalam proses *clustering* data. Algoritma K-Means berfungsi sebagai metode klasifikasi untuk mengelompokkan data berdasarkan CPK, membantu dalam menganalisis dan mengidentifikasi ban dengan biaya terendah per kilometer.

3.1.2 Implementasi dan Pengujian


Pada tahap pengumpulan data, penelitian ini menggunakan data dari PT. Puninar untuk periode 2023 mengenai penggantian ban, termasuk serial number, ukuran, merk, status ban, dan kriteria lainnya. Data tersebut kemudian diproses menggunakan pivot table di Microsoft Excel untuk mendapatkan informasi relevan seperti merk, ukuran, tyre distance, dan cost per kilometer (CPK) dari 1523 ban yang telah dilepas. Analisis menunjukkan hasil tyre distance dan CPK untuk berbagai merk ban, dengan rincian spesifik mengenai ban yang memiliki CPK terendah dan tertinggi. Selanjutnya, data tersebut diimpor ke RapidMiner Studio untuk implementasi metode K-Means. Proses *clustering* dengan K-Means membagi data menjadi tiga *cluster* berdasarkan nilai CPK: *Cluster 0* (CPK sedang), *Cluster 1* (CPK tertinggi), dan *Cluster 2* (CPK terendah). Hasil *clustering* menunjukkan distribusi data yang konsisten dengan analisis sebelumnya, mengidentifikasi ban dengan CPK terendah dan tertinggi sesuai kategori. Dalam tahap implementasi dan pengujian, kami menggunakan RapidMiner Studio versi 10.1 untuk menganalisis data. Dengan bantuan perangkat lunak ini, kami membandingkan hasil pengolahan data yang dilakukan secara manual dengan hasil dari software. Gambar 4 menunjukkan tampilan awal dari RapidMiner Studio versi 10.1 setelah proses loading selesai.



Gambar 4. Halaman Utama RapidMiner Studio v.10.1

Pada halaman utama RapidMiner Studio versi 10.1, terdapat lima menu utama: Start untuk memulai proses baru, Recent untuk membuka proses yang sudah ada, dan Learn yang menyediakan panduan penggunaan software. Untuk memulai proses kerja baru, pengguna memilih New Process

dan kemudian melakukan impor data dalam format .xls atau .xlsx. Proses impor data dilakukan dalam tiga tahap: memilih lokasi file, memilih sheet yang berisi data, dan menentukan tipe data serta atribut. Setelah data diimpor, pengguna menambahkan operator K-Means dan operator Performance. Pengaturan algoritma K-Means dilakukan dengan menentukan jumlah *cluster* yang diinginkan, dalam hal ini tiga *cluster*. Setelah proses running, hasil *clustering* ditampilkan dalam berbagai bentuk seperti Data View, Statistics View, Visualizations, dan Annotations. *Cluster Model* memberikan tampilan hasil pengelompokan berdasarkan *cluster* dan jumlah anggotanya, termasuk deskripsi dan visualisasi data dalam folder view.



Gambar 5. Tampilan Folder View Root *Cluster*

Folder View merupakan tampilan data bagian-bagian *cluster* secara keseluruhan. Penelitian ini mengidentifikasi tiga *cluster* berdasarkan nilai CPK (Cost Per Kilometer). *Cluster 0*, dengan kategori CPK mid, terdiri dari 15 item dengan nilai CPK antara 57 hingga 89, mencakup merek seperti ACHILES, BF GOODRICH, BRIDGESTONE, CHENGSAANG, DOUBLECOIN, DUNLOP, EFFIPLUS, GAJAH TUNGGAL, GITI, GOODYEAR, dan TRIANGLE. *Cluster 1*, dengan CPK tertinggi, terdiri dari 5 item dengan nilai CPK antara 101 hingga 148, termasuk merek seperti BRIDGESTONE, DOUBLECOIN, EFFIPLUS, dan GITI. *Cluster 2*, dengan CPK terendah, terdiri dari 28 item dengan nilai CPK antara 14 hingga 55, meliputi merek seperti BRIDGESTONE, CHENGSAANG, DOUBLECOIN, DUNLOP, DURATURN, GAJAH TUNGGAL, GITI, GOODRIDE, GOODYEAR, HANKOOK, QIMATIRES, THUNDERER, TRIANGLE, dan WINDA. Hasil analisis menggunakan Excel dan RapidMiner menunjukkan konsistensi dalam pembagian *cluster* dan data yang termasuk dalam setiap *cluster*.

3.2 Pembahasan

Hasil penelitian menunjukkan bahwa metode K-Means sangat efektif dalam mengelompokkan data ban berdasarkan biaya per kilometer (CPK). Proses klasterisasi ini menghasilkan panduan strategis yang penting bagi PT. Puninar dalam memilih ban dengan efisiensi biaya tertinggi. Hasil penelitian memperlihatkan tiga *cluster*: Cluster 0 dengan CPK sedang, Cluster 1 dengan CPK tertinggi, dan Cluster 2 dengan CPK terendah, dengan Cluster 2 menjadi fokus utama dalam upaya penghematan biaya operasional.

Konsistensi hasil penelitian selaras dengan beberapa studi yang menunjukkan efektivitas algoritma K-Means dalam mengklasifikasikan data berdasarkan kriteria efisiensi biaya, kinerja, dan kualitas. Sebagai contoh, penelitian Rahmah (2020) menunjukkan bahwa algoritma K-Means bermanfaat dalam pengelompokan data penjualan berdasarkan pola penjualan pestisida. Selain itu, penelitian Nugroho *et al.* (2022) yang menerapkan K-Means dalam manajemen data rumah sakit juga mendukung temuan ini, menunjukkan bahwa metode K-Means dapat memberikan hasil klasifikasi yang lebih terarah dalam pengelolaan sumber daya, termasuk dalam pengelolaan penggunaan ban.

Penggunaan perangkat lunak RapidMiner Studio dalam penelitian ini menghasilkan hasil klasterisasi yang detail. Cluster 2, yang terdiri dari 28 item dengan CPK terendah (antara 14 hingga 55), mencakup merek seperti Bridgestone, Chengsang, Giti, dan Goodyear. Ban dari merek-merek ini memiliki efisiensi biaya yang tinggi, sehingga direkomendasikan untuk digunakan dalam operasional PT. Puninar. Temuan ini sejalan dengan studi Andrean *et al.* (2019), yang menyatakan bahwa algoritma

K-Means efektif dalam membantu perusahaan mengoptimalkan pemilihan produk dengan mempertimbangkan efisiensi biaya, seperti yang terlihat pada klasterisasi persediaan aki.

Sebaliknya, Cluster 1 yang terdiri dari ban dengan CPK tertinggi (antara 101 hingga 148) menunjukkan bahwa meskipun kualitas merek seperti Bridgestone dan Doublecoin diakui, efisiensi biaya per kilometernya tidak memadai. Temuan ini memperkuat hasil penelitian Farahdinna *et al.* (2019), yang menunjukkan bahwa kualitas produk tidak selalu sebanding dengan efisiensi biaya, sehingga penting untuk mempertimbangkan faktor biaya dalam pengambilan keputusan terkait pengadaan produk.

Penggunaan Microsoft Excel untuk mengolah data sebelum diimpor ke RapidMiner memberikan validasi awal terhadap konsistensi hasil. Metode pivot table yang digunakan untuk menyaring data terbukti efektif, sebagaimana ditunjukkan oleh Solichin dan Khairunnisa (2020), yang menekankan pentingnya visualisasi dan penyaringan data dalam mendukung pengambilan keputusan berbasis data. Dalam penelitian ini, penggunaan kedua alat tersebut terbukti berhasil dalam mendukung analisis dan visualisasi hasil klasterisasi.

Penelitian Rohmatullah *et al.* (2019) juga mendukung hasil penelitian ini dengan menunjukkan bahwa algoritma K-Means efektif digunakan tidak hanya dalam sektor logistik, tetapi juga dalam sektor pertanian dan manufaktur, untuk meningkatkan efisiensi operasional. Ini menunjukkan bahwa metode ini bersifat serbaguna dan dapat diterapkan di berbagai bidang *data mining*, termasuk pengelolaan ban di PT. Puninar. Penelitian Priyatman *et al.* (2019) juga membuktikan akurasi metode K-Means dalam mengelompokkan data berdasarkan pola yang sulit diidentifikasi secara manual, menegaskan bahwa algoritma ini dapat digunakan dalam situasi yang kompleks seperti yang dihadapi dalam penelitian ini.

Hasil klasterisasi ini memberikan PT. Puninar kemampuan untuk memilih ban yang paling efisien secara strategis. Pengelompokan ban berdasarkan CPK akan membantu dalam penghematan biaya operasional jangka pendek serta meningkatkan efisiensi jangka panjang. Penelitian ini juga menunjukkan bahwa metode K-Means menyediakan dasar yang kuat untuk pengambilan keputusan yang lebih terarah dan berbasis data, yang sangat penting dalam pengelolaan armada logistik besar seperti yang dimiliki PT. Puninar. Penelitian tidak hanya bermanfaat bagi PT. Puninar, tetapi juga memperkuat bukti mengenai keandalan algoritma K-Means dalam pengelolaan logistik dan manajemen sumber daya. Temuan ini didukung oleh Saputro dan Sucihermayanti (2021), yang menyatakan bahwa metode K-Means sangat relevan untuk pengambilan keputusan berbasis data dalam berbagai sektor. Oleh karena itu, hasil penelitian ini merekomendasikan PT. Puninar untuk mempertimbangkan penggunaan ban dari Cluster 2 dalam upaya signifikan untuk mengurangi biaya operasional, sementara Cluster 1 dan Cluster 0 dapat digunakan sebagai pertimbangan untuk pengaturan anggaran lebih lanjut.

4. Kesimpulan

Berdasarkan analisis dan pengolahan data, penelitian ini menyimpulkan bahwa teknik data mining dengan metode k-means efektif dalam mengidentifikasi ban dengan CPK terendah. Penelitian ini berhasil mengelompokkan ban menjadi tiga *cluster* berdasarkan CPK: terendah, sedang, dan tertinggi. Metode k-means yang diuji dengan Excel dan RapidMiner menunjukkan konsistensi dalam hasil, menghasilkan tiga *cluster*, yaitu *Cluster 0* (CPK sedang, 15 item), *Cluster 1* (CPK tertinggi, 5 item), dan *Cluster 2* (CPK terendah, 28 item). Analisis ini merekomendasikan penggunaan ban dari *Cluster 2* dengan CPK terendah.

5. Daftar Pustaka

- Ali, A. (2019). Klasterisasi data rekam medis pasien menggunakan metode K-means *Clustering* di rumah sakit Anwar. *Jurnal MATRIK*, 19(1), 186-195. <https://doi.org/10.30812/matrik.v19i1.52>
- Andrean, R., Fendy, S., & Nugroho, A. (2019). Klasterisasi Pengendalian Persediaan Aki Menggunakan Metode K-Means. *JOINTECS Journal of Information Technology and Computer Science*, 4(1). <https://doi.org/10.31328/jointecs.v8i1.5078>
- Apriyani, P., Dikananda, A. R., & Ali, I. (2023). Penerapan Algoritma K-Means dalam Klasterisasi Kasus Stunting Balita Desa Tegalwangi. *Hello World Jurnal Ilmu Komputer*, 2(1).
- Ariyanto, D. (2022). Data Mining Menggunakan Algoritma K-Means Untuk Klasifikasi Penyakit Infeksi Saluran Pernafasan Akut. *Jurnal Sistim Informasi dan Teknologi*, 4(1), 13-18. <https://doi.org/10.37034/jsisfotek.v4i1.117>
- Farahdinna, F., Nurdiansyah, I., Suryani, A., & Wibowo, A. (2019). Perbandingan Algoritma K-Means dan K-Medoids dalam klasterisasi produk asuransi Perusahaan Nasional. <https://doi.org/10.26905/nomosleca.v4i2.2546>
- Fitri, E. M., Suryono, R. R., & Wantoro, A. (2023). Klasterisasi data penjualan berdasarkan wilayah menggunakan metode k-means pada PT XYZ. *Jurnal Koputasi Ilmu Komputer Unila Publishing Network*, 11(2). <https://doi.org/10.23960/komputasi.v11i2.12582>
- Harjono, S. W., Utami, N. W., & Putri, I. G. A. P. D. (2023). Klasterisasi Tingkat Penjualan pada Startup Panak.id dengan Algoritma K-Means. *Jurnal Ilmiah Teknologi Informasi Asia*, 17(1). <https://doi.org/10.32815/jitika.v17i1.888>
- Nugroho, M. R., Hendrawan, I. E., & Puwantoro. (2022). Penerapan Algoritma K-Means Untuk Klasterisasi Data Obat Pada Rumah Sakit ASRI. *JURNAL NUANSA INFORMATIKA*, 16(1). <https://doi.org/10.25134/nuansa.v16i1.5294>
- Nurahman, Purwanto, A., & Mulyanto, S. (2022). Klasterisasi Sekolah Menggunakan Algoritma K-Means berdasarkan Fasilitas, Pendidik, dan Tenaga Pendidik. *Matrik: Jurnal Manajemen, Teknik Informatika, dan Rekayasa Komputer*, 21(2). <https://doi.org/10.30812/matrik.v21i2.1411>
- Nurdiawan, A. F., & Anwar, S. (2018). Menggunakan K-Means dan Decission Tree. *Jurikom*, 8(6), 323–329. <https://doi.org/10.30865/jurikom.v8i6.3680>
- Oman Somantri, Slamet Wiyono, & Dairoh. (2016). Metode K-Means untuk Optimasi Klasifikasi Tema Tugas Akhir Mahasiswa Menggunakan Support Vector Machine (SVM). *Scientific Journal of Informatics*, 3(1). <https://doi.org/10.15294/sji.v3i1.5845>
- Priyatman, H., Sajid, F., & Haldivany, D. (2019). Klasterisasi Menggunakan Algoritma K-Means *Clustering* untuk Memprediksi Waktu Kelulusan Mahasiswa. *Jepin (Jurnal Edukasi dan Penelitian Informatika)*, 5(1).
- Rahmah, S. A. (2020). Klasterisasi pola penjualan pestisida menggunakan metode K-Means *Clustering* (studi kasus di toko Juanda Tani Kecamatan Hutabayu Raja). *Djtechno: Journal of Information Technology Research*, 1(1). <https://doi.org/10.46576/djtechno.v1i1.964>

- Rahmah, S. A., & Antares, J. (2021). Klasterisasi seleksi mahasiswa calon penerima beasiswa Yayasan menggunakan K-means Clustering. *Jurnal Informatika, Manajemen dan Komputer*, 13(2). <https://doi.org/10.36723/juri.v13i2.282>.
- Rohmatullah, A., Rahmalia, D., & Pradana, M. S. (2019). Klasterisasi data pertanian di Kabupaten Lamongan menggunakan algoritma K-means dan Fuzzy C Means. *Jurnal Ilmiah Teknosains*, 5(2). <https://doi.org/10.26877/jitek.v5i2.4254>
- Saputro, D. T., & Sucihermayanti, W. P. (2021). Penerapan Klasterisasi Menggunakan K-Means untuk Menentukan Tingkat Kesehatan Bayi dan Balita di Kabupaten Bengkulu Utara. *Jurnal Buana Informatika*, 12(2), 146-155. <https://doi.org/10.24002/jbi.v12i2.4861>
- Satria, C., & Anggrawan, A. (2021). Aplikasi K-Means Berbasis Web untuk Klasifikasi Kelas Unggulan. *Jurnal Manajemen, Teknik Informatika, dan Rekayasa Komputer*, 21(1), 111–124. <https://doi.org/10.30812/matrik.v21i1.1473>
- Solichin, A., & Khairunnisa, K. (2020). Klasterisasi Persebaran Virus Corona (Covid-19) di DKI Jakarta Menggunakan Metode K-Means. *Fountain of Informatics Journal*, 5(2). <https://doi.org/10.21111/fij.v5i2.4905>
- Wahyu, A., & Rushendra. (2018). Klasterisasi Dampak Bencana Gempa Bumi Menggunakan Algoritma K-Means di Pulau Jawa. *Jurnal Edukasi dan Penelitian Informatika*. <https://doi.org/10.14257/IJGDC.2018.11.8.08>
- Wandana, J., Defit, S., & Sumijan. (2020). Klasterisasi Data Rekam Medis Pasien Pengguna Layanan BPJS Kesehatan Menggunakan Metode K-Means. *Jurnal Informasi dan Teknologi*, 2(4), 119-125. <https://doi.org/10.37034/jidt.v2i4.73>.