EXPLORE
Jurnal Sistem Informasi dan Telematika
(Telekomunikasi, Multimedia dan Informatika)

Analisis Karakteristik Kendaraan dan Pola Kepadatan Lalu Lintas Menggunakan Clustering dan Analisis Time Series Terhadap Data Weigh-in-Motion

Abdul Malik Karim, Dona Yuliawati*
Jurusan Sistem Informasi
Fakultas Ilmu Komputer
Institut Informatika dan Bisnis Darmajaya
Bandar Lampung, Indonesia
abdul.2411050079p@mail.darmajaya.ac.id, donayuliawati@darmajaya.ac.id*

Abstract-This study aims to analyse the vehicle characteristics and traffic density pattern at Mayjen Yusuf Singedekane road section on Palembang which is under the observation of Unit Pelaksana Penimbangan Kendaraan Bermotor (UPPKB) Kertapati by using clustering and time series analysis to process the data recorded by Weigh-in-Motion (WIM) device. The data used in this study includes the time of record, total vehicle weight, number of axles, and weight per axle. The first analysis is performing clustering of the vehicles by weight and axle charactersitics using k-Means clustering method. Second step of the analysis is by finding the traffic density pattern using time series analysis STL Decomposition method to find a short seasonal cycle. These two analysis are done using Orange data mining tool. The result of this study separates the data into 3 clusters: C1 Light represents vehicles with low weight regardless of axles, C2 Heavy represents vehicles with heavy load and focuses on axle configurations between 2 to 4 axles, C3 Large-Heavy represents vehicles with heavy load and focuses on axle configurations between 5 to 6 axles. This study determines that the weekly density pattern peaks at Friday and reaches the lowest point at Saturday. Hopefully these findings are able to contribute to the planning of traffic management and road infrastructure maintenance efforts among other potential uses.

Keywords: Weigh-in-Motion, k-Means Clustering, Time Series Analysis, STL Decomposition, Data Mining.

Abstrak-Penelitian ini bertujuan untuk menganalisis karakteristik kendaraan dan pola kepadatan lalu lintas pada Ruas Jalan Mayjen Yusuf Singedekane Palembang yang berada dibawah pengawasan Unit Pelaksana Penimbangan Kendaraan Bermotor (UPPKB) Kertapati dengan menggunakan Clustering dan Analisis Time Series terhadap data yang direkam oleh perangkat Weigh-in-Motion (WIM). Data yang digunakan mencakup waktu rekam, berat total kendaraan, jumlah sumbu, serta beban per sumbu. Analisis pertama yaitu mengelompokkan kendaraan berdasarkan beban dan karakteristik sumbu mengunakan metode K-Means clustering. Analisis kedua yaitu mengidentifikasi pola kepadatan lalu lintas menggunakan Analisis Time Series metode STL Decomposition untuk menemukan pola musiman jangka pendek. Kedua analisis tersebut dilakukan dengan menggunakan program data mining Orange. Hasil akhir penelitian ini mengelompokkan data menjadi tiga cluster yaitu: C1 Ringan adalah kendaraan dengan berat yang rendah tanpa melihat jumlah sumbu, C2 Berat adalah kendaraan dengan berat kendaraan yang tinggi dan berfokus pada jumlah sumbu antara 2 dan 4, C3 Besar-Berat adalah kendaraan dengan berat yang tinggi dan berfokus pada jumlah sumbu antara 5 dan 6. Penelitian ini menemukan bahwa pola kepadatan mingguan mencapai puncaknya pada hari Jum'at dan berada pada titik terendah pada hari Sabtu. Hasil penelitian ini diharapkan dapat membantu perencanaan manajemen lalu lintas dan pemeliharaan infrastruktur jalan serta kegiatan lain yang penelitian ini berpotensi untuk digunakan.

Kata Kunci: Weigh-in-Motion, k-Means Clustering, Analisis Time Series, STL Decompostion, Data Mining

1. Pendahuluan

Komposisi kendaraan dan frekuensi dari berbagai jenis kendaraan yang melintas memiliki dampak signifikan terhadap keadaan dari suatu jaringan jalan dan daerah disekitanya. Dengan demikian diperlukan pemahaman mengenai kendaraan macam apakah serta sepadat apa volume lalu lintas yang terjadi di suatu jaringan jalan untuk dapat melakukan perencanaan terhadap pengelolaan infrastruktur jalan dan membantu proses pengambilan keputusan dalam pengoperasian jalan [1]. Salah satu cara yang dapat dilakukan untuk mengetahui hal tersebut adalah dengan melakukan analisis dari karakteristik kendaraan dan pola kepadatan lalu lintas yang terdapat pada suatu jaringan jalan. Untuk mendapatkan data yang dapat digunakan sebagai bahan

This work is licensed under a Creative Commons Attribution 4.0 International License

dalam proses analisis tersebut dapat dilakukan menggunakan berbagai macam metode, namun salah satu metode yang memberikan data yang lengkap dan akurat adalah dengan menggunakan perangkat *Weigh-In-Motion* (WIM) yang dirancang untuk mengukur dan merekam data entitas kendaraan seperti beban per sumbu serta berat total kendaraan secara otomatis saat kendaraan melintas tanpa menghentikan arus lalu lintas [2].

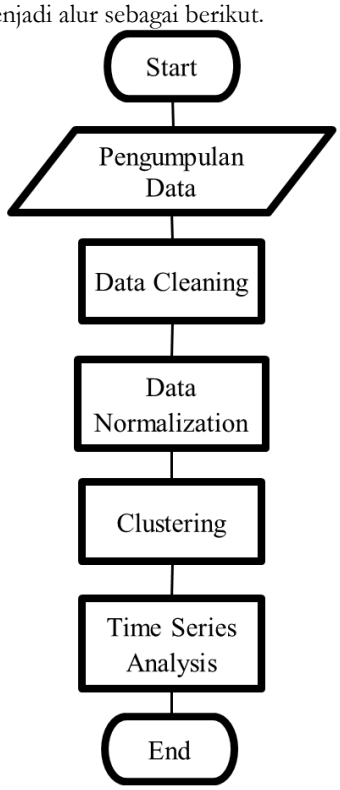
Jumlah kendaraan yang melewati suatu jalan dipengaruhi oleh seberapa pentingnya akses jalan tersebut terhadap jaringan jalan keseluruhan. Sebagai jalan nasional yang memberikan akses keluar masuk kota Palembang untuk kendaraan angkutan barang besar, jalan Mayjen Yusuf Singedekane setiap hari dilewati oleh berbagai jenis kendaraan mulai dari kendaraan roda dua hingga truk *18-wheeler* dan lebih dengan jumlah kendaraan yang sangat banyak setiap harinya. Oleh karena itu, data WIM yang didapatkan dari ruas jalan tersebut bersifat *high volume* dan multivariabel sehingga memerlukan metode analisis yang efisien dan objektif. Salah satu metode analisis tersebut adalah K-Means clustering yang sering digunakan terhadap data lalu lintas berskala besar untuk klasifikasi kendaraan dan penemuan pola lalu lintas [3]. Hal ini menjadikan metode K-Means sebagai pendekatan clustering dasar dalam melakukan analisis lalu lintas [4].

Selain karakteristik kendaraan, analisis lain yang dapat memberikan pemahaman terhadap keadaan suatu jalan adalah analisis terhadap pola kepadatan lalu lintas. Data kepadatan lalu lintas umumnya berbentuk deret waktu yang dipengaruhi oleh keadaan dan tren seperti hari besar atau libur nasional yang mengakibatkan fluktuasi terhadap data yang didapatkan. Untuk dapat menemukan sebuah pola dari data yang berfluktuasi tersebut diperlukan metode analisis yang dapat melihat dan menguraikan struktur tren dan variasi dalam sebuah data. Salah satu metode yang dapat melakukan hal tersebut adalah *Seasonal-Trend Decomposition using Loess* (STL) yang mendukung analisis detail dari variasi lalu lintas yang tidak permanen [5]. Metode dekomposisi seperti STL juga sering digunakan untuk analisis data lalu lintas secara eksploratif [6].

Integrasi antara analisa metode clustering dan time series terhadap data WIM dapat membantu memahami hubungan antara karakteristik kendaraan dan pola kepadatan lalu lintas seperti yang telah dilakukan oleh beberapa penelitian terdahulu [1][7][8]. Penelitian ini bermaksud untuk menggabungkan pendekatan K-Means untuk pengelompokan karakteristik kendaraan dan mengungkap heterogenitas populasi kendaraan dengan STL untuk menemukan komponen musiman jangka pendek dan memisahkan variasi temporal sehingga analisis data yang lebih terperinci dapat dilakukan terhadap data WIM pada ruas jalan Mayjen Yusuf Singedekane.

2. Metodologi

Penelitian ini terbagi menjadi beberapa tahapan yang tersusun menjadi alur sebagai berikut.



Gambar 1. Alur penelitian

A. Pengumpulan Data

Data yang digunakan untuk penelitian ini diperoleh dengan mengambil data yang direkam oleh perangkat WIM yang terpasang pada ruas jalan Mayjen Yusuf Singedekane, yang diawasi oleh Unit Pelaksana Penimbangan Kendaraan Bermotor (UPPKB) Kertapati. Data yang digunakan adalah data berat kendaraan pada bulan September 2025 yang berjumlah 407.835 baris data.

B. Data Cleaning

Pembersihan data atau Data cleaning merupakan tahap awal dalam proses data mining yang bertujuan untuk menghilangkan data tidak lengkap, data duplikat, dan data yang tidak konsisten [9]. Proses ini sangat penting dilakukan khususnya untuk data yang didapatkan dari perangkat sensor yang terotomatisasi penuh tanpa campur tangan manusia seperti yang ditemukan pada perangkat WIM karena data tersebut sering mengandung berbagai jenis kesalahan seperti missing data, ketidakpastian, dan *noise* yang perlu dideteksi dan dikoreksi untuk menjamin kualitas data sebelum dianalisis [10]. Data kendaraan yang digunakan dalam penelitian ini sebelumnya telah mengalami proses data cleaning yang menghapus baris data dengan berat total bernilai 0, oleh karena itu langkah pembersihan data yang akan dilakukan adalah mencari data duplikat dan berat sumbu yang tidak sesuai dengan berat total serta jumlah sumbu. Hasil dari pembersihan data menghapus sebanyak 7.606 baris data

This work is licensed under a Creative Commons Attribution 4.0 International License

dengan data yang siap diolah berjumlah 400.247 baris data.

Tabel 1. Data Kendaraan Setelah Pembersihan

Waktu Rekam	Berat Total (kg)	Sumbu 1 (Kg)	Sumbu 2 (Kg)	Sumbu 3 (Kg)	Sumbu 4 (Kg)	Sumbu 5 (Kg)	Sumbu 6 (Kg)	Jumlah Sumbu
2025-09-01 00:00:52.649	29600	6450	23150	0	0	0	0	2
2025-09-01 00:00:56.368	2150	550	1050	550	0	0	0	3
2025-09-01 00:01:05.700	1300	650	650	0	0	0	0	2
2025-09-01 00:01:40.988	12050	2700	9350	0	0	0	0	2
2025-09-01 00:01:43.030	25300	6250	5700	8350	5000	0	0	4
2025-09-01 00:01:46.237	23350	4050	4900	8700	5700	0	0	4
2025-09-01 00:01:49.737	12600	3250	9350	0	0	0	0	2
2025-09-01 00:01:52.143	17950	6600	3400	3950	4000	0	0	4
2025-09-01 00:02:06.798	1100	550	550	0	0	0	0	2
2025-09-01 00:02:15.328	13000	3100	5950	3950	0	0	0	3
2025-09-01 00:02:38.440	850	250	600	0	0	0	0	2
2025-09-01 00:02:54.918	1300	600	700	0	0	0	0	2
2025-09-01 00:02:59.657	10200	2300	7900	0	0	0	0	2
2025-09-01 00:03:12.780	8300	2250	6050	0	0	0	0	2
2025-09-01 00:03:36.111	20800	6950	5300	6000	2550	0	0	4
2025-09-01 00:03:39.100	24250	4550	5900	7200	6600	0	0	4
2025-09-01 00:03:42.891	10950	5150	5800	0	0	0	0	2
2025-09-01 00:03:49.016	1550	550	1000	0	0	0	0	2
2025-09-01 00:03:53.609	2250	850	1400	0	0	0	0	2
2025-09-01 00:04:02.577	12550	3700	8850	0	0	0	0	2

C. Data Normalization

Normalisasi data merupakan proses penskalaan nilai atribut ke dalam rentang tertentu agar setiap atribut memiliki kontribusi yang seimbang dalam proses analisis [11]. Tahapan ini penting dilakukan sebelum melakukan pengolahan data dengan metode clustering untuk memastikan bahwa setiap variabel berkontribusi secara seimbang terhadap perhitungan jarak, sehingga fitur bergantung pada skala besar tidak menguasai pembentukan cluster [12]. Dengan melakukan normalisasi data, nilai dari kolom berat total yang lebih besar dari kolom lainnya terutama dibandingkan dengan kolom jumlah sumbu tidak akan mendominasi kontribusi pada saat pelaksanaan tahap clustering.

Metode normalisasi yang akan digunakan adalah metode Z-Score yang mentransformasikan data sehingga memiliki rata-rata nol dan simpangan baku satu [11]. Berikut rumus matematis proses normalisasi Z-Score:

$$z_i = \frac{x_i - \mu}{\sigma}$$

- z_i = nilai hasil normalisasi Z-Score
- x_i = nilai data ke-i
- μ = nilai rata-rata atribut
- σ = simpangan baku atribut

EXPLORE: ISSN: 2087-2062, Online ISSN: 2686-181X / DOI: http://dx.doi.org/10.36448/jsit.v17i1.4737
This work is licensed under a Creative Commons Attribution 4.0 International License

Penggunaan metode Z-Score dipilih karena metode ini tidak membatasi rentang hasil transformasi dan sesuai untuk data yang tidak memiliki batas minimum dan maksimum yang tetap.

D. Clustering

Clustering merupakan teknik data mining yang bertujuan untuk mengelompokkan data ke dalam beberapa kelompok berdasarkan tingkat kemiripan tertentu [11]. Proses clustering dipilih dalam penelitian ini karena clustering efektif diterapkan pada data numerik multivariabel untuk menemukan pola dan struktur tersembunyi dalam dataset tanpa label, di mana objek yang serupa dikelompokkan bersama sehingga pola kompleks dalam dataset yang berukuran besar dapat diidentifikasi [13].

Metode clustering yang digunakan dalam penelitian ini adalah K-Means yang mengelompokkan data kedalam cluster berdasarkan perhitungan jarak antar data yang umumnya menggunakan jarak Euclidean [9]. Berikut rumus matematis penghitungan jarak Euclidean yang digunakan dalam metode K-Means:

$$d(x_i, x_j) = \sqrt{\sum_{l=1}^{m} (x_{il} - x_{jl})^2}$$

- $d(x_i, x_j)$ = jarak Euclidean antara data ke-i dan data ke-j
- x_{il} = nilai atribut ke-l dari data ke-i
- x_{jl} = nilai atribut ke-l dari data ke-j
- m = jumlah atribut atau dimensi data

Metode K-Means dipilih dalam penelitian ini karena kemampuannya dalam mengelompokkan data berskala besar secara efisien serta kemudahannya dalam menginterpretasi hasil cluster.

E. Time Series Analysis

Data deret waktu atau *time series* adalah kumpulan data yang tercatat secara berurutan berdasarkan urutan waktu tertentu [14]. Analisis terhadap data deret waktu salah satunya adalah dekomposisi, yang dilakukan dengan menguraikan komponen tren, musiman, dan keacakan untuk memahami pola historis dan dinamika perubahan data dari waktu ke waktu untuk mengidentifikasi pola musiman dan fluktuasi periodik dalam data. [11].

Metode analisis deret waktu yang digunakan dalam penelitian ini adalah *Seasonal and Trend decomposition using Loess* (STL) yaitu metode dekomposisi yang memisahkan data menjadi komponen tren, musiman, dan residual menggunakan pendekatan LOESS (*Locally Estimated Scatterplot Smoothing*) [6]. Metode ini terpilih karena ketahanannya terhadap *noise* dan kemampuannya dalam mengidentifikasi pola musiman secara adaptif.

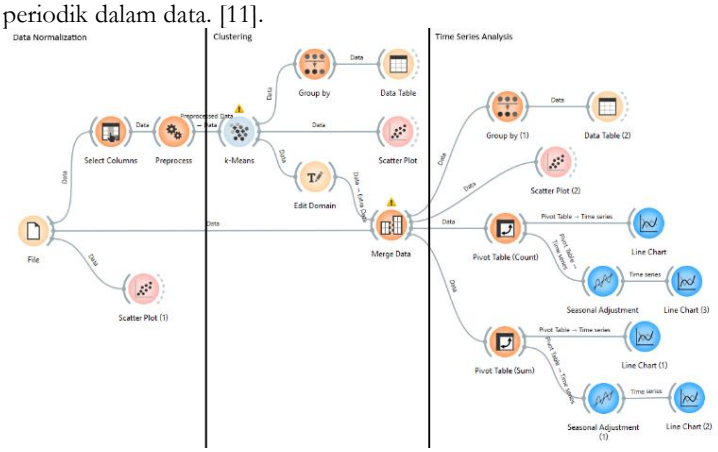
3. Hasil dan Pembahasan

Pengolahan data dilakukan menggunakan metode clustering dengan algoritma K-Means. Data yang akan diolah adalah data kendaraan yang terekam oleh perangkat Weigh-In-Motion (WIM) yang terpasang pada ruas jalan Mayjen Yusuf Singedekane Palembang yang berada dibawah pengawasan Unit Pelaksana Penimbangan Kendaraan Bermotor (UPPKB) Kertapati. Rentang data yang diolah adalah data kendataan selama bulan September 2025, dan kolom data yang akan diolah menggunakan metode clustering adalah kolom yang berisi data yang terkait dengan penentuan kluster berat kendaraan yaitu jumlah sumbu, berat per sumbu (1-6), dan berat total kendaraan.

Pengolahan data selanjutnya dilakukan dengan metode Time Series Analysis untuk mencari pola musiman (Seasonal Pattern) jangka pendek menggunakan algoritma *Seasonal-Trend decomposition using Loess* (STL Decomposition). Data yang diolah adalah hasil clustering dari data berat kendaraan dan data waktu rekam kendaraan.

Untuk membantu proses pengolahan data akan digunakan aplikasi data mining yaitu *Orange*. Penggunaan aplikasi ini diperlukan karena data yang akan diolah berjumlah sangat besar yaitu sebanyak 400.247 baris data. Pengolahan data dalam aplikasi orange dilakukan dengan menghubungkan *tools* yang relevan dengan metode yang akan digunakan sampai akhirnya menghasilkan alur kerja aplikasi yang melakukan pengolahan data sesuai dengan yang diinginkan oleh pengguna.

Alur pengolahan data yang dipakai dalam penelitian ini terbagi menjadi tiga kategori tahapan sesuai dengan alur penelitian yang telah dibahas sebelumnya yaitu Data Normalization, Clustering, dan Time Series Analysis.

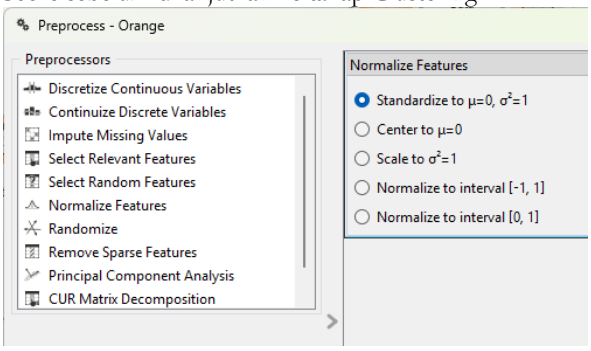


EXPLORE: ISSN: 2087-2062, Online ISSN: 2686-181X / DOI: http://dx.doi.org/10.36448/jsit.v17i1.4737
This work is licensed under a Creative Commons Attribution 4.0 International License

Gambar 2. Alur pengolahan data menggunakan aplikasi data mining *Orange*

A. Data Normalization

Tahap normalisasi data terdiri dari *tools* yang bertujuan untuk memasukkan data kedalam aplikasi *Orange* yaitu File, untuk kemudian diolah lebih lanjut dengan *tools* Preprocessing untuk melakukan normalisasi metode Z-Score sebelum dilanjutkan ke tahap Clustering.

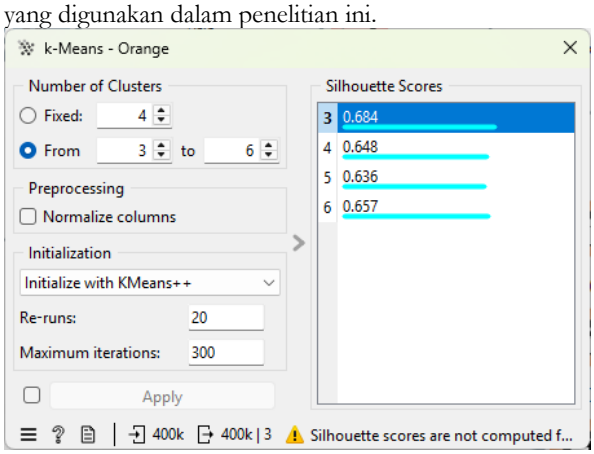


Gambar 3. Jendela Preprocess yang digunakan untuk melakukan normalisasi data

B. Clustering

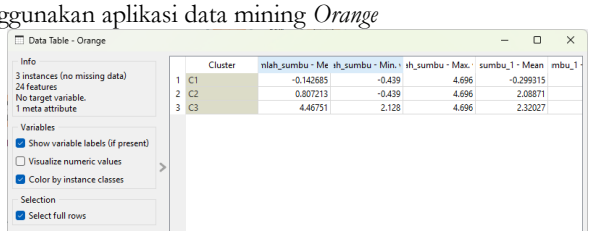
Tahap clustering merupakan tahapan yang terdiri dari proses algoritma K-Means yang dilanjutkan dengan penentuan definisi tiap cluster secara manual dengan melihat agregasi data setelah dilakukan clustering.

Untuk melakukan clustering dengan algoritma k-means dilakukan menggunakan *tools* k-Means. Dalam menentuka jumlah cluster yang akan digunakan dalam mengelompkkan data penelitian ini menggunakan penghitungan *silhouette score* dengan rentang jumlah cluster antara tiga sampai enam titik. Hasil akhirnya adalah cluster berjumlah tiga titik memiliki *silhouette score* lebih tinggi dari titik lainnya, dan terpilih sebagai jumlah cluster yang digunakan dalam penelitian ini.



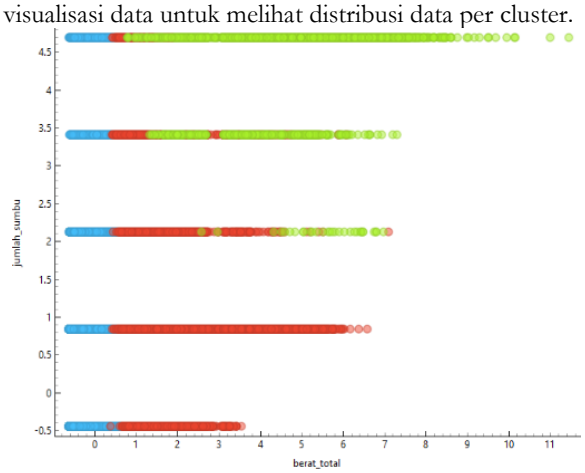
Gambar 4. Jendela k-Means beserta nilai *silhouette score* untuk tiap jumlah cluster

Setelah mengolah data kendaraan dengan metode clustering selanjutnya perlu ditemukan definisi dari tiap titik cluster. Hal ini dilakukan dengan melihat dua jenis interpretasi terhadap data yang telah diolah, yang pertama adalah melihat agregasi data per cluster.



Gambar 5. Mendefinisikan cluster melalui agregasi data per cluster

Interpretasi kedua adalah dengan menggunakan visualisasi data untuk melihat distribusi data per cluster.



Gambar 6. Visualisasi cluster menggunakan scatter plot

Menggunakan dua interpretasi tersebut, definisi tiap cluster dapat diidentifikasi sebagai berikut:

- **C1 Ringan**

Merupakan cluster dengan kendaraan ringan tanpa melihat jumlah sumbu kendaraan. Contoh kendaraan dalam cluster ini yaitu kendaraan penumpang dan kendaraan angkutan barang tidak bermuatan atau bermuatan ringan. Kendaraan dalam cluster ini berjumlah 350.337 kendaraan dan mencakup 87,53% dari total jumlah kendaraan.

- **C2 Berat**

Merupakan cluster dengan kendaraan berat dengan melihat sumbu kendaraan. Sumbu kendaraan yang masuk mencakup semua jumlah sumbu namun dengan fokus ke sumbu kecil yaitu 2-4 sumbu. Contoh kendaraan dalam cluser ini adalah kendaraan angkutan barang dengan muatan. Kendaraan dalam cluster ini berjumlah 47.260 kendaraan dan mencakup 11,81% dari total jumlah kendaraan.

- **C3 Besar-Berat**

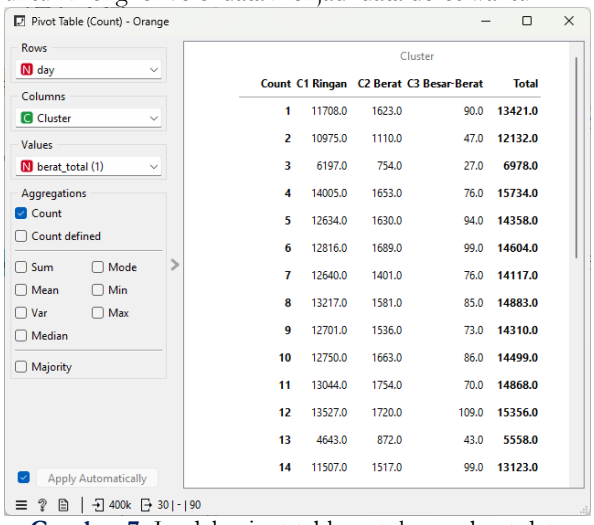
Merupakan cluster dengan kendaraan berat dan memiliki sumbu antara 4-6 sumbu dengan fokus ke 5-6 sumbu yang merupakan karakteristik kendaraan angkutan barang dengan kapasitas besar. Contoh kendaraan dalam cluster ini adalah adalah kendaraan angkutan barang jenis kereta penarik beserta kereta gandengnya. Kendaraan dalam cluster ini berjumlah 2.650 kendaraan dan mencakup 0,66% dari total jumlah kendaraan.

C. Time Series Analysis

Setelah ditemukan cluster untuk data berat kendaraan maka tahap selanjutnya adalah menemukan pola musiman

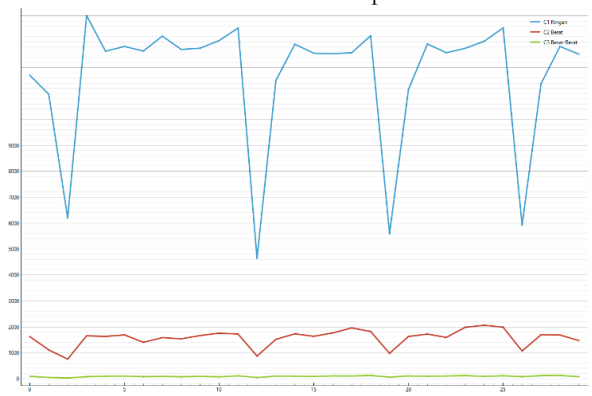
EXPLORE: ISSN: 2087-2062, Online ISSN: 2686-181X / DOI: http://dx.doi.org/10.36448/jsit.v17i1.4737
This work is licensed under a Creative Commons Attribution 4.0 International License

jangka pendek menggunakan time series analysis algoritma STL Decomposition. Hal ini dilakukan dengan menggunakan *tools* yaitu Seasonal Adjustment terhadap data yang sebelumnya diolah menggunakan pivot table untuk mengkonversi data menjadi data deret waktu.



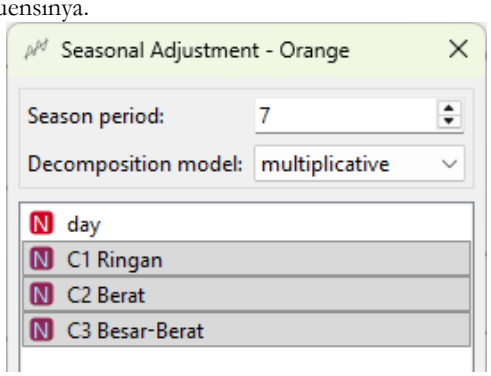
Gambar 7. Jendela pivot table untuk membuat data deret waktu

Data yang telah diolah menjadi bentuk deret waktu dapat dilihat melalui diagram garis untuk menemukan distribusi kendaraan untuk bulan September 2025.



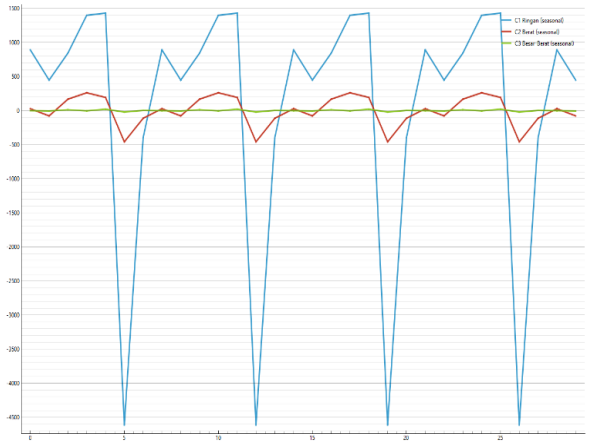
Gambar 8. Distribusi kendaraan per cluster selama bulan September 2025

Untuk melakukan seasonal adjustment, rentang waktu yang dipakai adalah harian yang akan didistribusikan per minggu agar dapat ditemukan pola musiman jangka pendek mingguan. Pola musiman juga akan diproses melalui model dekomposisi aditif dan multiplikatif agar dapat terlihat pola musiman baik keseluruhan atau variasi frekuensinya.

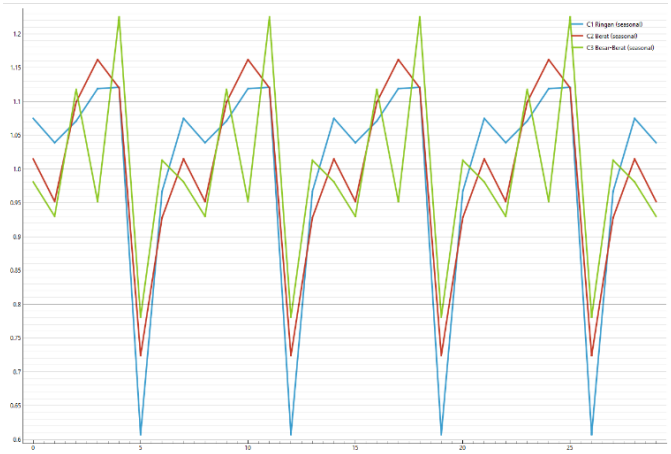


Gambar 9. Jendela seasonal adjustment untuk menemukan pola mingguan dari data frekuansi cluster harian

Hasil dari pengolahan STL decomposition data kendaraan adalah berupa diagram garis yang berisi pola musiman frekuensi cluster mingguan.



Gambar 10. Hasil pengolahan STL Decomposition model aditif



Gambar 11. Hasil pengolahan STL Decomposition model multiplikatif

This work is licensed under a Creative Commons Attribution 4.0 International License

4. Kesimpulan

Dengan melihat pola musiman tersebut berikut data cluster dan data berat kendaraan dapat ditemukan hasil penelitian sebagai berikut:

Jumlah frekuensi terendah berada pada hari Sabtu untuk ketiga jenis cluster.

Untuk cluster C1 Ringan, frekuensi kendaraan terus meningkat stabil dari hari Sabtu ke Jum'at dengan adanya penurunan pada tiap hari Selasa, dan puncaknya berada pada hari Jum'at. Dengan jumlah anggota cluster yang banyak, setiap kenaikan dan penurunan frekuensi kendaraan terjadi dalam jumlah yang signifikan. Pada bulan September 2025, jumlah kendaraan yang termasuk dalam golongan cluster C1 pada hari tertinggi berjumlah 14.005 kendaraan dan pada hari terendah berjumlah 4.643 kendaraan dengan selisih berjumlah 9.362 kendaraan atau 301,64%.

Untuk cluster C2 Berat, frekuensi kendaraan mengalami peningkatan drastis setiap hari Rabu dan mencapai puncaknya pada hari Kamis. Variasi kenaikan dan penurunan frekuensi kendaraan pada cluster ini lebih stabil dari cluster C1. Jumlah kendaraan yang termasuk dalam golongan cluster C2 pada hari tertinggi berjumlah 2.060 kendaraan dan pada hari terendah berjumlah 754 kendaraan dengan selisih berjumlah 1.306 kendaraan atau 273,21%.

Untuk cluster C3 Besar-Berat, frekuensi kendaraan mengalami turun naik setiap hari dengan puncaknya berada pada hari Jum'at, namun dengan jumlah anggota cluster yang lebih sedikit menyebabkan jumlah kendaraan cluster C3 yang melintas tidak mengalami banyak perubahan terutama dibandingkan dengan cluster lainnya. Jumlah kendaraan yang termasuk dalam golongan cluster C3 pada hari tertinggi berjumlah 123 kendaraan dan pada hari terendah berjumlah 27 kendaraan dengan selisih berjumlah 96 kendaraan atau 455,56%.

5. Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada pihak-pihak yang dengan dukungan serta bantuannya penulis dapat menyelesaikan karya ilmiah ini, yaitu:

Unit Pelaksana Penimbangan Kendaraan Bermotor (UPPKB) Kertapati, sebagai instansi pengawas kendaraan angkutan barang pada ruas jalan Mayjen Yusuf Singedekane.

PT. Jalintim Adhi Abipraya, sebagai Badan Usaha Pelaksana UPPKB Kertapati yang telah memberikan izin kepada penulis untuk menggunakan data perangkat WIM yang digunakan dalam karya ilmiah ini.

Institut Informatika dan Bisnis Darmajaya, yang memberikan bimbingan kepada penulis dalam penyelesaian karya ilmiah ini serta menyediakan berbagai literatur studi yang penulis gunakan untuk mendalami pemahaman terhadap topik yang penulis bahas [15][16][17][18][19][20].

Tim Redaksi Jurnal EXPLORE Universitas Bandar Lampung, yang telah memberikan kesempatan untuk menerbitkan karya ilmiah ini.

6. Daftar Pustaka

[1] M. Treiber and A. Kesting, *Traffic Flow Dynamics: Data, Models and Simulation*. Berlin, Germany: Springer, 2013. ISBN: 9783642324604

[2] Federal Highway Administration, *LTBP Program's Literature Review on Weigh-In-Motion Systems*, U.S. Department of Transportation, Washington, DC, USA, 2016. [Online]. Available: https://www.fhwa.dot.gov/publications/research/infrastructure/structures/ltbp/16024/001.cfm

[3] J. Han, M. Kamber, and J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed. Waltham, MA, USA: Morgan Kaufmann, 2012. ISBN: 9780123814791

[4] R A. Jain, M. N. Murty, and P. Flynn, "Data clustering: A review," *ACM Computing Surveys*, vol. 31, no. 3, pp. 264–323, 1999. doi: 10.1145/331499.331504

[5] C. Bergmeir, R. J. Hyndman, and B. Koo, "A note on the validity of cross-validation for evaluating autoregressive time series prediction," *Computational Statistics & Data Analysis*, vol. 120, pp. 70–83, 2018. doi: 10.1016/j.csda.2017.11.003

[6] R. B. Cleveland, W. S. Cleveland, J. E. McRae, and I. Terpenning, "STL: A seasonal-trend decomposition procedure based on loess," *Journal of Official Statistics*, vol. 6, no. 1, pp. 3–33, 1990. ISSN: 0282-423X

[7] Q. Li, K. P. Wang, M. Eacker, and Z. Zhang, "Clustering Methods for Truck Traffic Characterization in Pavement ME Design," *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering*, vol. 3, no. 2, Art. F4016003, 2017, doi: 10.1061/AJRUA6.0000881

[8] L. Elefteriadou, *An Introduction to Traffic Flow Theory*. New York, NY, USA: Springer, 2014, doi: 10.1007/978-1-4614-8435-6

[9] Kusrini dan E. T. Luthfi, *Algoritma Data Mining*. Yogyakarta, Indonesia: Andi Offset, 2009, ISBN: 978-979-29-0809-1

[10] H. Teh, A. Kempa-Liehr, & K. Wang, "Sensor data quality: a systematic review," *Journal of Big Data*, vol. 7, no. 57, 2020. doi: 10.1186/s40537-020-0285-1

[11] E. Prasetyo, *Data Mining: Konsep dan Aplikasi Menggunakan MATLAB*. Yogyakarta, Indonesia: Andi Offset, 2014, ISBN: 978-979-294-351-1

[12] S. E. Saqila, I. P. Ferina, dan A. Iskandar, "Analisis perbandingan kinerja clustering data mining untuk normalisasi dataset," *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 5, no. 2, pp. 356–365, 2023, doi: 10.30865/json.v5i2.6919

[13] E, Pastuchová, and Š, Václavíková, "Cluster Analysis – Data Mining Technique for Discovering Natural Groupings in the Data," *Journal of Electrical Engineering*, vol. 64, no. 2, pp. 128–131, 2013, doi: 10.2478/jee-2013-0019

[14] S. G. Makridakis, S. C. Wheelwright, dan R. J. Hyndman, *Forecasting: Methods and Applications*, 3rd

This work is licensed under a Creative Commons Attribution 4.0 International License

ed. New York, NY, USA: John Wiley & Sons, 1997. ISBN: 0471532339

[15] D. Yuliawati, R. Kurniawan, B. Nugroho, S. Y. Irianto, dan S. Karnila, "Vehicle image segmentation using mobile-based K-mean clustering to determine tax costs in supporting regional basic income," *AIP Conference Proceedings*, vol. 2614, no. 1, Art. no. 040015, 2023. doi: 10.1063/5.0127960

[16] D. Yuliawati, R. Kurniawan, B. Nugroho, S. Y. Irianto, and S. Karnila, "Internet of things for monitoring parking system using optical character recognition," *Jurnal Infotel*, vol. 15, no. 2, pp. 169–174, May 2023. doi: 10.20895/infotel.v15i2.859

[17] B. Nugroho, M. S. Mahfudz, A. Andriyadi, and D. Yuliawati, "Sistem Otomatisasi Pajak Parkir Kendaraan Bermotor Menggunakan Raspberry Pi dan Image Processing," *Explore: Jurnal Sistem Informasi dan Telematika (Telekomunikasi, Multimedia dan Informatika)*, vol. 14, no. 2, 2023. doi: 10.36448/jsit.v14i2.3322

[18] E. Pranadjaya, E. S. Pangestu, C. O. Sereati, S. Octaviani, dan M. Darmawan, "Perbandingan Algoritma Machine Learning menggunakan Orange Data Mining untuk Klasifikasi Jenis Kendaraan pada Sistem Tilang Digital," *Jurnal Elektro*, vol. 17, no. 1, pp. 41–47, 2024. doi: 10.30736/je.v17i1.1218

[19] R. R. Andarista dan A. Jananto, "Penerapan Data Mining Algoritma C4.5 Untuk Klasifikasi Hasil Pengujian Kendaraan Bermotor," *Jurnal Tekno Kompak*, vol. 16, no. 2, pp. 29–43, 2022. doi: 10.33365/jtk.v16i2.1648

[20] B A. F. D. Nugroho, H. Firmansyah, dan W. Asriyani, "Penerapan Data Mining untuk Prediksi Evaluasi Mobil dengan Metode Decision Tree," *Jurnal Pustaka Cendekia Hukum dan Ilmu Sosial*, vol. 3, no. 3, pp. 277–286, 2025. doi: 10.70182/jpchis.v3i3.253

This work is licensed under a Creative Commons Attribution 4.0 International License