

PENERAPAN METODE K-MEANS BERBASIS JARAK UNTUK DETEksi KENDARAAN BERGERAK

Yuslena Sari^{*1}, Andreyan Rizky Baskara², Puguh Budi Prakoso³

^{1,2,3}Universitas Lambung Mangkurat, Banjarmasin

¹yuzlena@ulm.ac.id, ²andreyan.baskara@ulm.ac.id, ³puguh.prakoso@ulm.ac.id

*Penulis Korespondensi

(Naskah masuk: 31 Oktober 2021, diterima untuk diterbitkan: 12 Agustus 2022)

Abstrak

Deteksi kendaraan bergerak adalah salah satu elemen penting dalam aplikasi *Intelligent Transport System* (ITS). Deteksi kendaraan bergerak juga merupakan bagian dari pendekripsi benda bergerak. Metode K-Means berhasil diterapkan pada piksel *cluster* yang tidak diawasi untuk mendekripsi objek bergerak. Secara umum, K-Means adalah algoritma heuristik yang mempartisi kumpulan data menjadi K *cluster* dengan meminimalkan jumlah kuadrat jarak di setiap cluster. Dalam makalah ini, algoritma K-Means menerapkan jarak Euclidean, jarak Manhattan, jarak Canberra, jarak Chebyshev dan jarak Braycurtis. Penelitian ini bertujuan untuk membandingkan dan mengevaluasi implementasi jarak tersebut pada algoritma clustering K-Means. Perbandingan dilakukan dengan basis K-Means yang dinilai dengan berbagai parameter evaluasi yaitu MSE, PSNR, SSIM dan PCQI. Hasilnya menunjukkan bahwa jarak Manhattan memberikan nilai MSE = 1.328, PSNR = 21.14, SSIM = 0.83 dan PCQI = 0.79 terbaik dibandingkan dengan jarak lainnya. Sedangkan untuk waktu pemrosesan data memerlukan bahwa jarak Braycurtis memiliki keunggulan lebih yaitu 0.3 detik.

Kata kunci: berbasis jarak, deteksi kendaraan bergerak, clustering, metode K-Means

APPLICATION OF DISTANCE-BASED K-MEANS METHOD FOR MOVING VEHICLE DETECTION

Abstract

Detection moving vehicles is one of important elements in the applications of Intelligent Transport System (ITS). Detection moving vehicles is also part of the detection of moving objects. K-Means method has been successfully applied to unsupervised cluster pixels for the detection of moving objects. In general, K-Means is a heuristic algorithm that partitioned the data set into K clusters by minimizing the number of squared distances in each cluster. In this paper, the K-Means algorithm applies Euclidean distance, Manhattan distance, Canberra distance, Chebyshev distance and Braycurtis distance. The aim of this study is to compare and evaluate the implementation of these distances in the K-Means clustering algorithm. The comparison is done with the basis of K-Means assessed with various evaluation parameters, namely MSE, PSNR, SSIM and PCQI. The results exhibit that the Manhattan distance delivers the best MSE = 1.328, PSNR = 21.14, SSIM = 0.83 and PCQI = 0.79 values compared to other distances. Whereas for data processing time exposes that the Braycurtis distance has more advantages

Keywords: *Detection of moving vehicles; Clustering; Distance-based; method K-Means.*

1. PENDAHULUAN

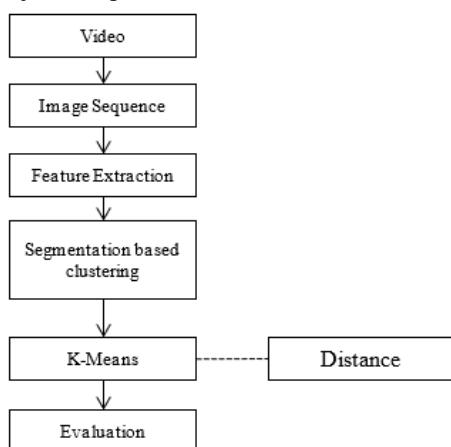
Deteksi kendaraan bergerak adalah proses penting untuk Intelligent Transport System (ITS). Deteksi kendaraan yang bergerak adalah bagian dari deteksi objek bergerak. Masalah ini merupakan bagian penting yang mendasari dalam pemantauan lalu lintas dan banyak aplikasi lainnya. Masalah deteksi objek bergerak telah banyak dipelajari, analisis dan teknik - teknik terbaru sudah diusulkan seperti *Adaptive Threshold Algorithm*, *Clustering*

Algorithms dan lain-lain (Zhang dkk., 2017; Chacon-murguia dkk., 2019; Tang dkk., 2018; Qin, Snoussi dan Abdallah, 2014; Bachir dkk., 2014; Guido dkk., 2014). *Clustering* adalah teknik untuk mengkategorikan data ke dalam kelompok. Metrik jarak memainkan peran yang sangat penting dalam proses pengelompokan. Semakin banyak kesamaan di antara data dalam kelompok, semakin besar kemungkinan item-item data tertentu menjadi milik kelompok tertentu. Ada sejumlah algoritma yang tersedia untuk pengelompokan. Secara umum, K-

means adalah algoritma heuristik yang mempartisi data yang ditetapkan ke dalam cluster K dengan meminimalkan jumlah jarak kuadrat di setiap cluster (Rodriguez dkk., 2019; Rafsanjani dkk., 2012). Kekuatan algoritma k-means adalah karena efisiensi komputasi dan sifat kemudahan yang dapat digunakan. Metrik jarak digunakan untuk menemukan objek data serupa yang mengarah pada pengembangan algoritma yang kuat untuk fungsionalitas penambangan data seperti klasifikasi dan pengelompokan (Pambudi, Andono dan Pramunendar, 2018), (Nasir, 2018). Penelitian sebelumnya (Meng, Lv dan Ma, 2020) metode K-means digunakan untuk mengelompokkan data arus lalu lintas. Tahap algoritma K-Means yang digunakan adalah pusat pengelompokan K diinisialisasi. Kemudian, jarak dari data ke pusat cluster dihitung, dan data tersebut dibagi menjadi pusat cluster terdekat. Pusat setiap cluster adalah pusat dari semua titik sampel dari semua cluster. Dalam tulisan ini, hasil yang diperoleh dengan menerapkan algoritma K-means menggunakan metrik yang berbeda yaitu jarak Manhattan, jarak Canberra, jarak Chebyshev dan jarak dengan studi perbandingan hasil algoritma K-means dasar yang diimplementasikan melalui metrik jarak Euclidian untuk data dua dimensi didiskusikan. Hasilnya ditampilkan dengan bantuan histogram.

2. METODE DIUSULKAN

Data awal berupa video kemudian diubah menjadi frame, dari frame berupa citra di ekstrak sebagai inputan untuk metode K-Means, metode K-Means merupakan metode klustering dimana metode klustering dilakukan berdasarkan jarak yang berbeda. Setelah mendapatkan hasil kluster yg berupa vector maka diubah menjadi matrix kembali dan background dijadikan putih dan foreground jadi hitam. Foreground di sesuaikan dgn warna citra asli sedangkan background dibiarkan tetap putih. Selanjutnya, dievaluasi dengan metode evaluasi seperti MSE, PSNR, SSIM dan PCQI. Alur metode yang diajukan seperti Gambar 1.



Gambar 1. Alur metode diusulkan

2.1. Deteksi Kendaraan Bergerak

Tahap proses dalam deteksi kendaraan dibagi dalam beberapa tahap:

1. Pengambilan data

Data yang digunakan adalah data video kendaraan di jalan raya. Proses pengambilan gambar menggunakan kamera. Data disimpan dalam format video. Alasan pemilihan pengujian dalam bentuk video adalah supaya untuk menguji apakah aplikasi dapat berjalan secara real time.

2. Image Sequence

Data video dirubah kedalam image sequence yaitu potongan gambar yang terurut dari sebuah video. Proses perubahan video menjadi image sequence diawali dengan penginputan video. Selanjutnya adalah proses read video, pada proses ini video akan dibaca tiap framenya. Setelah video dibaca, dilakukan looping terhadap semua frame pada video. Proses selanjutnya

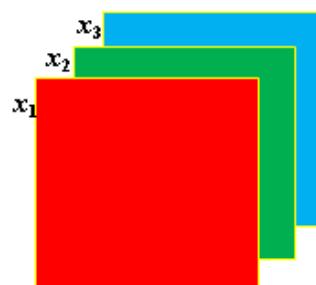
adalah memberikan label nama, data yang digunakan sebanyak 400 frame data. Contoh data salah satu frame dari video ditunjukkan pada Gambar 2.



Gambar 2. Contoh data citra dari frame ke-200

2.2. Feature Extraction

Teknik feature extraction yang digunakan adalah merubah matrix RGB yang berisikan piksel menjadi data vector. Operasi pemrosesan gambar dari matrix RGB ke data vector dimulai dari menyimpan data RGB yaitu komponen Merah (x_1), Hijau (x_2) dan Biru (x_3) pada gambar 3(Dev dkk., 2016; Kepuska, Gonzales dan et al, 2012).



Gambar 3. Ilustrasi warna RGB

Karenanya setiap piksel yang dilihat sebagai satu set nilai RGB:

$$z = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}$$

di mana:

" x_1 " adalah intensitas piksel pada gambar Merah

" x_2 " adalah intensitas piksel pada gambar Hijau

" x_3 " adalah intensitas piksel pada gambar Biru

Gambar warna RGB ukuran $M \times N$ dapat diwakili oleh: Tiga gambar komponen dengan ukuran ini, atau total vektor MN ukuran 3×1 . Kasus multispektral umum yang melibatkan gambar komponen n akan menghasilkan vektor n -dimensi (Wang, 2010; Dev dkk., 2016; Kepuska, Gonzales dan et al, 2012):

$$z = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ \dots \\ x_n \end{bmatrix}$$

Adapun ilustrasi perubahan matrix ke vector di tunjukkan pada gambar 4:

$$z = \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{bmatrix}$$

(a)

$$z = \begin{bmatrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \\ 8 \\ 9 \end{bmatrix}$$

(b)

Gambar 4. Ilustrasi perubahan piksel matrix RGB (a) ke vector (b)

Fitur ekstraksi dilakukan dengan mengekstrak R, G, dan B menjadi vector dan dijadikan 1 data untuk tiap frame.

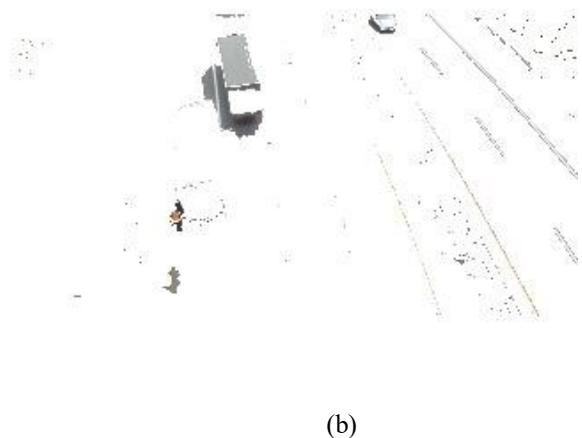
2.3. Segmentation Based Clustering

Segmentasi citra dianggap sebagai operasi dasar yang penting untuk analisis dan interpretasi yang bermakna terhadap citra yang diperoleh (Gao, Zhang dan Chen, 2012; Christodoulou, Kasparis dan Marques, 2011; Spagnolo dkk., 2006; Dhanachandra, Manglem dan Chanu, 2015). Proses segmentasi adalah membedakan objek dari latar belakang dan objek yang tidak diinginkan. Bagian pemrosesan ini bertanggung jawab untuk mengidentifikasi kendaraan yang bergerak dari objek statis atau latar belakang. Gambar dipartisi ke dalam kelompok piksel yang homogen sehubungan dengan beberapa kriteria. Kelompok yang berbeda tidak boleh saling berpotongan dan kelompok yang berdekatan harus heterogen. Kotak pembatas ditentukan berdasarkan rasio daerah yang tertarik ketika melakukan analisis gumpalan(Realization dkk., 2018; Abramov,

Skriftsov dan Kazantsev, 2015; Mou dkk., 2018). Gambar 5 menunjukkan hasil sebelum dan setelah segmentasi.



(a)



(b)

Gambar 5. Hasil segmentasi dari gambar original (a) menjadi gambar setelah segmentasi (b)

2.4. K-Means

Algoritma clustering k-means menggunakan jarak Euclidean (Sindhu dkk., 2017; No dan Singh, 2013) untuk mengukur kesamaan antara objek. Selain menggunakan jarak Euclidean, metrik jarak yang lain juga dapat digunakan dan metode ini disebut metode median-K. Metode median-K mencoba untuk menghilangkan kelemahan metode K-means karena kurang sensitif terhadap outlier. Adapun tahapan algoritma K-Means adalah sebagai berikut:

- Biarkan K menjadi jumlah cluster.
- Pilih poin K yang akan diambil sebagai centroid untuk kelompok K . Poin-poin ini dapat dipilih secara acak. Kriteria ini valid kecuali jika pengguna memiliki beberapa tampilan terperinci ke dalam data.
- Hitung jarak dengan menggunakan rumus Euclidian / rumus jarak yang lain untuk setiap titik data di set dari masing-masing centroid yang dipilih.
- Setiap objek ke kluster terdekat berdasarkan nilai jarak yang dihitung pada langkah di atas.

- Hitung centroid cluster lagi dengan menghitung nilai rata-rata atribut dari semua objek di setiap cluster.
- Analisis keanggotaan cluster berubah atau tidak berubah, jika tidak berubah maka ini adalah langkah terakhir jika tidak maka kembali ke langkah menghitung jarak.

2.5. Distance

Pada Penelitian ini ada beberapa perhitungan jarak yang digunakan untuk dianalisis pada tahap hasil nanti. Jarak tersebut adalah:

- Euclidean Distance

Euclidean Distance digunakan karena dapat menentukan panjang jalur terpendek antara dua titik, sehingga dapat mengetahui kedekatan antara dua fitur.

Persamaan *Euclidean Distance* ditunjukkan pada persamaan 1 sebagai berikut:

$$D = \sqrt{(X_2 - X_1)^2 + (Y_2 - Y_1)^2} \quad (1)$$

- Canberra Distance

Canberra Distance digunakan karena dapat menghitung nilai-nilai yang sesuai, pada data tersebut. Kemudian nilai-nilai tersebut dibandingkan berdasarkan peringkat, sehingga dapat mempertimbangkan jarak antara dua titik dan keterkaitannya. Selain itu

Persamaan *Canberra Distance* seperti pada persamaan 2 sebagai berikut :

$$Canb(x, y) = \sum_{i=1}^d \frac{|x_i - y_i|}{|x_i| + |y_i|} \quad (2)$$

- Chebyshev Distance

Chebyshev Distance digunakan karena dapat menentukan jarak terbesar dari perbedaan setiap titik koordinat. Chebyshev Distance seperti pada persamaan 3 adalah sebagai berikut:

$$d_{chebyshev}(x, y) = \max_i(|x_i - y_i|) \quad (3)$$

- Manhattan Distance

Manhattan Distance juga dikenal sebagai jarak bujursangkar, jarak blok kota didefinisikan sebagai segmen titik ke sumbu koordinat. Manhattan seperti pada persamaan 4 adalah sebagai berikut:

$$d_M(x_1 - x_2) = \sum_{i=1}^n |x_i - y_i| \quad (4)$$

- Braycurtis Distance

Braycurtis Distance digunakan karena dapat mengukur ketidaksamaan antara dua lokasi yang berbeda, berdasarkan perhitungan di setiap lokasi. Braycurtis Distance seperti pada persamaan 5 adalah sebagai berikut:

$$d_{Braycurtis} = \frac{\sum |x_i - y_i|}{\sum (x_i + y_i)} \quad (5)$$

2.6. Evaluation

Untuk mengevaluasi beberapa metode perhitungan jarak yang digunakan pada K-Means, penelitian ini menggunakan beberapa pengukuran sebagai berikut:

- Mean Square Error (MSE)

Mean Square Error (MSE) merupakan pengukuran kualitas yang dihitung berdasarkan 2 buah citra yang dibandingkan, sehingga dapat diketahui tingkat ketidaksesuaian antara citra tersebut (Zheng, n.d.; Kalirajan dan Sudha, 2015; Jachner, van den Boogaart dan Petzoldt, 2007). Semakin kecil nilai MSE yang dihasilkan maka semakin sesuai citra yang dibandingkan tersebut. Persamaan MSE dijabarkan sebagai berikut:

$$MSE = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (x(i, j) - y(i, j))^2 \quad (6)$$

- Peak Signal To Noise Ratio (PSNR)

Peak signal to noise ratio (PSNR) merupakan pengukuran kualitas yang dihitung berdasarkan 2 buah objek citra yang dibandingkan seperti MSE (Wolf dan Pinson, 2009; Chaurasia dan Sharma, 2015; Preedanan dkk., 2018). Perbandingan antara nilai maksimum dari sinyal yang diukur dengan besarnya derau yang berpengaruh pada sinyal tersebut. Hasil yang diperoleh dari PSNR dikatakan semakin mirip jika nilai PSNR semakin besar. PSNR biasanya diukur dalam satuan decibel (db) yang dituliskan dalam persamaan (6).

$$PSNR = 10 \log_{10} \left(\frac{MAX^2}{MSE} \right) \quad (7)$$

- Structural SIMilarity (SSIM)

Structural similarity (SSIM) digunakan untuk menghitung indeks kesamaan antara 2 buah objek citra yang dibandingkan secara structural (Chacon-murguia dkk., 2019; Larkin, 2015). Nilai dari SSIM menunjukkan bahwa 2 buah citra memiliki kesamaan secara structural jika mendekati angka 1. Formula SSIM berdasarkan perbandingan 3 pengukuran luminance, kontras dan struktur. Formula SSIM dapat diringkas seperti pada persamaan (8) dengan ketentuan nilai α , β dan γ adalah 1.

$$SSIM(x, y) = \frac{\left((2\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2) \right)^{\frac{1}{2}}}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (8)$$

- Patch-based Contrast Quality Index (PCQI)

Patch-based contrast quality index (PCQI) memiliki konsep seperti SSIM yang digunakan untuk menghitung indeks kesamaan antara 2 buah objek citra (Wang, 2010), (Maharaj dan Naidoo, 2018; Khan dkk., 2018) PCQI menggunakan 20% presentasi berbasis patch yang memungkinkan sebagian citra inputan baru terbagi menjadi 3 komponen bermakna secara fisik. Kekuatan pada komponen ditentukan oleh sistem koordinat baru, namun komponen

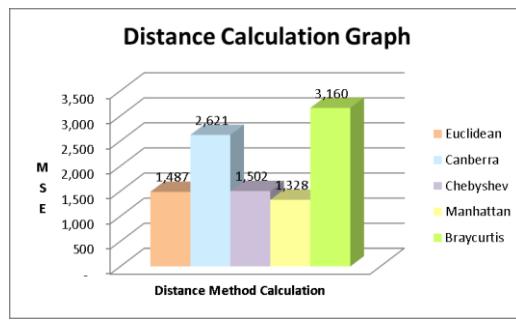
evaluasi menghasilkan nilai menjadi lebih dari 1 jika terjadi peningkatan citra. Rata-rata dari formula PCQI dituliskan dalam persamaan (9), dan formula PCQI jelaskan dalam persamaan (10) berdasarkan perbandingan 3 pengukuran intensitas, kontras dan struktur.

$$PCQI(x, y) = \frac{1}{M} \sum_{j=1}^M PCQI(x_j, y_j) \quad (9)$$

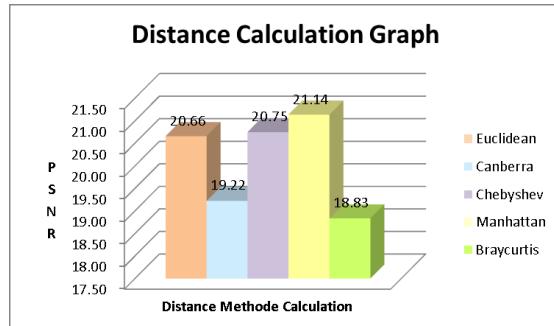
$$PCQI(x, y) = q_i(x, y) * q_c(x, y) * q_s(x, y) \quad (10)$$

3. HASIL DAN PEMBAHASAN

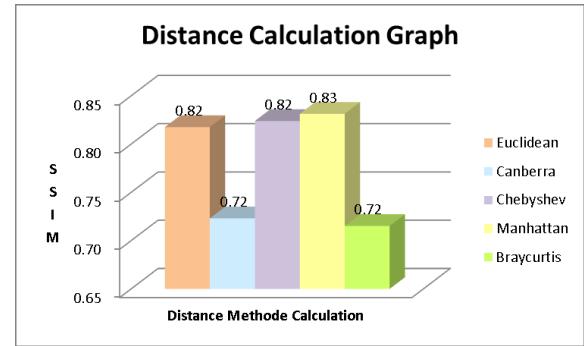
Hasil perhitungan deteksi kendaraan dilakukan dengan cara melakukan perhitungan jarak dimana jumlah citra yang digunakan sebanyak 400 data. Berdasarkan hasil yang telah dilakukan menggunakan Euclidean Distance, Canberra Distance, Chebyshev Distance, Manhattan Distance, dan Braycurtis Distance pada K-Means, maka dapat dilakukan perbandingan dari nilai MSE, PSNR, SSIM dan PCQI yang dihasilkan seperti tampak pada tabel 1, Gambar 6, 7, 8, dan 9 di bawah ini:



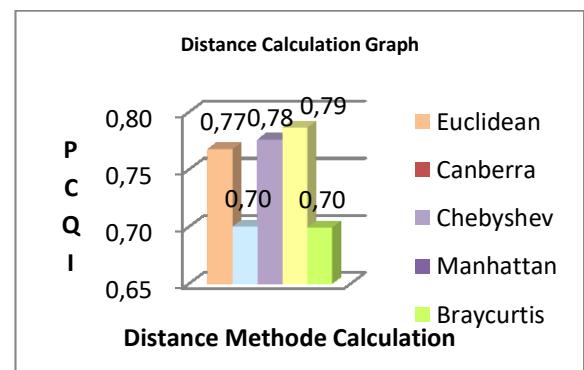
Gambar 6. Hasil Evaluasi MSE



Gambar 7. Hasil Evaluasi PSNR



Gambar 8. Hasil Evaluasi SSIM



Gambar 9. Hasil Evaluasi PSNR

Dari hasil evaluasi, MSE yang paling kecil dengan nilai 1,328 dihasilkan oleh jarak Manhattan dan jarak Manhattan juga menghasilkan nilai PSNR yang paling tinggi yaitu 21,14. Nilai PSNR yang lebih tinggi menyiratkan kemiripan yang lebih erat antara hasil rekonstruksi dan gambar asli. Begitupun dengan SSIM, jarak Manhattan menghasilkan nilai yang mendekati 1 yaitu 0,83. Nilai dari SSIM menunjukkan memiliki kesamaan secara structural jika mendekati angka 1. Untuk hasil PCQI, jarak Manhattan juga memiliki nilai yang paling baik dibanding dengan jarak yang lain yaitu mendekati 1 bernilai 0,79. Adapun hasil perbandingan waktu dapat dilihat pada tabel 2 berikut:

Tabel 2. Hasil Ecaluasi Waktu

Jarak	Waktu
Euclidean	2.889
Canberra	23.339
Chebyshev	0.381
Manhattan	0.348
Braycurtis	0.300

Hasil analisis waktu, jarak Braycurtis yang memiliki waktu terpendek atau tercepat dalam proses data yaitu 0,3 second.

Tabel 1. Hasil Evaluasi Jarak

	Euclidean	Canberra	Chebyshev	Manhattan	Braycurtis	Evaluation
	1487.056704	2620.657	1502.033	1328.147	3159.799292	MSE
	20.65784169	19.22424	20.74845	21.13607	18.83470784	PSNR
	0.817551531	0.723066	0.823867	0.831358	0.715181703	SSIM
	0.767853418	0.700277	0.776038	0.786532	0.699320642	PCQI

4. PENUTUP

Nilai evaluasi jarak dengan metode K-Means menunjukkan jarak Manhattan memiliki nilai terbaik dari perbandingan dengan jarak Euclidean, jarak Canberra, jarak Chebyshev dan jarak Braycurtis. Evaluasi jarak Manhattan memiliki terbaik dibanding dengan jarak yang lain dari hasil evaluasi menggunakan MSE, PSNR, SSIM dan PCQI dengan nilai MSE = 1.328, PSNR = 21.14, SSIM = 0.83 dan PCQI = 0.79. Sedangkan untuk proses kecepatan data yang memiliki keunggulan adalah jarak Braycurtis. Untuk saran selanjutnya adalah mencoba perbandingan jarak dengan basis metode cluster yang lain.

DAFTAR PUSTAKA

- ABRAMOV, K.V., SKRIBTSOV, P.V. dan KAZANTSEV, P.A., 2015. Image Segmentation Method Selection for Vehicle Detection Using Unmanned Aerial Vehicle. 9(5), hal.295–303.
- BACHIR, B.M., TAREK, B., SENLIN, L. dan HOCINE, L., 2014. Weighted Samples Based Background Modeling for the Task of Motion Detection in Video Sequences. TELKOMNIKA, 12(11), hal.7778–7784.
- CHACON-MURGUIA, M.I., GUZMAN-PANDO, A., RAMIREZ-ALONSO, G. dan RAMIREZ-QUINTANA, J.A., 2019. A novel instrument to compare dynamic object detection algorithms ☆. Image and Vision Computing, [daring] 88, hal.19–28. Tersedia pada: <<https://doi.org/10.1016/j.imavis.2019.04.006>>.
- CHAURASIA, K. dan SHARMA, N., 2015. Performance Evaluation and Comparison of Different Noise , apply on PNGImage Format used in Deconvolution Wiener filter (FFT) Algorithm. Evolving Trends in Engineering and Technology, 4, hal.8–14.
- CHRISTODOULOU, L., KASPARIS, T. dan MARQUES, O., 2011. Advanced statistical and adaptive threshold techniques for moving object detection and segmentation. 2011 17th International Conference on Digital Signal Processing DSP, hal.1–6.
- DEV, S., MEMBER, S., LEE, Y.H. dan MEMBER, S., 2016. Color-based Segmentation of Sky / Cloud Images From Ground-based Cameras. XX(Xx), hal.1–12.
- DHANACHANDRA, N., MANGLEM, K. DAN CHANU, Y.J., 2015. Image Segmentation Using K -means Clustering Algorithm and Subtractive Clustering Algorithm. Procedia Computer Science, 54, hal.764–771.
- GAO, S., ZHANG, C. DAN CHEN, W.B., 2012. An improvement of color image segmentation through projective clustering. Proceedings of the 2012 IEEE 13th International Conference on Information Reuse and Integration, IRI 2012, hal.152–158.
- GUIDO, G., VITALE, A., SACCOMANNO, F.F., ASTARITA, V. DAN GIOFRÈ, V., 2014. Vehicle Tracking System based on Videotaping Data. Procedia - Social and Behavioral Sciences, 111, hal.1123–1132.
- JACHNER, S., VAN DEN BOOGAART, K.G. DAN PETZOLDT, T., 2007. Statistical Methods for the Qualitative Assessment of Dynamic Models with Time Delay (R Package qualV). Journal of Statistical Software, [daring] 22(8), hal.1–30. Tersedia pada: <<http://www.jstatsoft.org/>>.
- KALIRAJAN, K. DAN SUDHA, M., 2015. Moving Object Detection for Video Surveillance. 2015.
- KEPUSKA, V., GONZALES, R. dan et al, 2012. Vector & Matrix Operations: Digital Image Processing.
- KHAN, A., SAAD, S., ALI, A., ANWER, A., ADIL, S.H. dan MERIAUDEAU, F., 2018. Subsea Pipeline Corrosion Estimation by Restoring and Enhancing Degraded Underwater Images. IEEE Access, 6, hal.40585–40601.
- LARKIN, K.G., 2015. Structural Similarity Index SSIMplified : (1), hal.1–4.
- MAHARAJ, M.R. dan NAIDOO, B., 2018. An Analysis of Objective and Human Assessments in Contrast Enhancement. 13(22), hal.15843–15859.
- MENG, X., LV, J. dan MA, S., 2020. Applying improved K-means algorithm into official service vehicle networking environment and research. Soft Computing, [daring] 24(11), hal.8355–8363. Tersedia pada: <<https://doi.org/10.1007/s00500-020-04893-w>>.
- MOU, L., MEMBER, S., ZHU, X.X. dan MEMBER, S., 2018. Vehicle Instance Segmentation from Aerial Image and Video Using a Multi-Task Learning Residual Fully Convolutional Network. IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING, hal.1–14.
- NASIR, I.S., 2018. The Proposed Image Segmentation Method Based On Adaptive K-Means Algorithm. 96(21), hal.7054–7064.
- NO, I. DAN SINGH, S.P., 2013. Study of K-Means and Enhanced K-Means Clustering Algorithm. International Journal of Advanced Research in Computer Science, 4(10).
- PAMBUDI, E.A., ANDONO, P.N. dan PRAMUNENDAR, R.A., 2018. Image Segmentation Analysis Based On K-Means

- PSO By Using Three Distance Measures. 9102(August), hal.1821–1826.
- PREEDANAN, W., KONDO, T., BUNNUN, P., KUMAZAWA, I. dan IMAGES, A.V., 2018. A Comparative Study of Image Quality Assessment. hal.2–5.
- QIN, L., SNOUSSI, H. dan ABDALLAH, F., 2014. Object tracking using adaptive covariance descriptor and clustering-based model updating for visual surveillance. Sensors (Switzerland), 14(6), hal.9380–9407.
- RAFSANJANI, M.K., VARZANEH, Z.A., CHUKANLO, N.E., RAFSANJANI, M.K., VARZANEH, Z.A. dan CHUKANLO, N.E., 2012. A survey of Hierarchical Clustering Algorithms. The Journal of Mathematics and COnputer Science, 5(3), hal.229–240.
- REALIZATION, D., FUTSUHARA, K., ZHANG, Y., WANG, J., YANG, X., IWASAKI, Y., KAWATA, S. dan NAKAMIYA, T., 2018. Multiple Vehicle Detection and Segmentation in Malaysia Traffic Flow. IOP Conference Series: Materials Science and Engineering PAPER.
- RODRIGUEZ, M.Z., ID, C.H.C., CASANOVA, D., BRUNO, O.M., AMANCIO, D.R., COSTA, L.F. dan RODRIGUES, F.A., 2019. Clustering algorithms: A comparative approach. hal.1–34.
- SINDHU, R., NANDAL, R., DHAMIJA, P., SEHRAWAT, H. dan SCIENCE, C., 2017. A Review On K-mean Algorithm And It ' S Different Distance. 9(2), hal.1423–1430.
- SPAGNOLO, P., ORAZIO, T.D., LEO, M. dan DISTANTE, A., 2006. Moving object segmentation by background subtraction and temporal analysis. 24, hal.411–423.
- TANG, C., HU, H., ZHANG, M., WANG, W., WANG, X., CAO, F. dan LI, W., 2018. Real-time detection of moving objects in a video sequence by using data fusion algorithm. Transactions of the Institute of Measurement and Control, hal.1–12.
- WANG, C.-T.A.T., 2010. MATLAB for Image Processing.
- WOLF, S. dan PINSON, M., 2009. Reference Algorithm for Computing Peak Signal to Noise Ratio (PSNR) of a Video Sequence with a Constant Delay. hal.1–18.
- ZHANG, C., REN, J., FAN, L. dan YU, C., 2017. A Novel Method of Preceding Vehicle Detection and Vehicle Distance Measurement Based on Monocular Vision. Revista de la Facultad de Ingeniería U.C.V., 32, hal.92–98.
- ZHENG, S., n.d. Methods of Evaluating Estimators Mean Square Error (MSE) of an Estimator. In: Statistical Theory II Methods. hal.1–11.

Halaman ini sengaja dikosongkan