

Parameter Tuning dalam Klasifikasi Load Factor pada Bus Rapid Transit (BRT)

Muhammad Iman Nur Hakim¹, Joko Siswanto^{2*}, Aninditya Anggari Nuryono³

¹Teknologi Rekayasa Otomotif, Politeknik Keselamatan Transportasi Jalan

²Rekayasa Sistem Transportasi Jalan, Politeknik Keselamatan Transportasi Jalan

³Informatika, Institut Teknologi Kalimantan

¹m.iman@pktj.ac.id, ²siswanto@pktj.ac.id *, ³anindityanuryono@gmail.com

Abstract

Public transport services are facing more challenges and some problems are gradually emerging with the increase in public transport users and varying travel demands. Determining efficiency, service feasibility and operational costs of BRT public transport refers to load factor. Load factor classification on BRT using KNN is proposed with parameter tuning to increase accuracy values. The dataset used is data on Corridor 1 BRT Transjatin routes with 148 routes between stops and vice versa. The KNN algorithm with parameter tuning on 2 types of matrices (Minkowski and Euclidean) uses 75% training data and 25% test data for classification of BRT load factors for Transjatin corridor 1. The BRT load factor classification using the KNN algorithm increased by 7.81% by tuning the parameters in the Euclidean matrix compared to the Minkowski matrix. The increase in accuracy is reflected in the confusion matrix with changes in increasing true negatives and decreasing false positives. Category 1 has a higher class than category 2 for boarding and alighting passengers. The classification presented can be a reference for Transjatin Corridor 1 Managers in determining efficiency, feasibility and operational costs.

Keywords: transportation, BRT, load factor, classification, KNN

Abstrak

Layanan angkutan umum menghadapi lebih banyak tantangan dan beberapa masalah yang secara bertahap muncul seiring dengan peningkatan pengguna angkutan umum dan berbagai permintaan perjalanan. Penentuan efisiensi, kelayakan layanan, dan biaya operasional angkutan umum BRT mengacu pada load factor. Klasifikasi load factor pada BRT menggunakan KNN diusulkan dengan tuning parameter untuk meningkatkan nilai akurasi. Dataset yang digunakan yaitu data trayek Koridor 1 BRT Transjatin dengan rute antar halte dan sebaliknya sebanyak 148 data. Algoritma KNN dengan tuning parameter pada 2 jenis matrix (Minkowski dan Euclidean) menggunakan data latihan sebesar 75% dan data uji sebesar 25% untuk klasifikasi load factor BRT untuk koridor 1 Transjatin. Klasifikasi load factor BRT dengan algoritma KNN mengalami kenaikan 7.81% dengan tuning parameter pada matrix Euclidean dibandingkan matrix Minkowski. Peningkatan akurasi tergambar pada confusion matrix dengan perubahan pada peningkatan true negative dan penurunan pada false positive. Kategori 1 memiliki kelas yang lebih tinggi dibandingkan kategori 2 untuk penumpang naik dan penumpang turun. Klasifikasi yang disajikan dapat menjadi rujukan Pengelola Transjatin Koridor 1 dalam menentukan efisiensi, kelayakan, dan biaya operasional.

Kata kunci: transportasi, BRT, load factor, klasifikasi, KNN

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

1. Pendahuluan

Penggunaan angkutan umum menjadi semakin populer di banyak kota dengan meningkatnya kemacetan lalu lintas[1]. Pembangunan infrastruktur angkutan umum di perkotaan juga telah menarik lebih banyak orang untuk menggunakan angkutan umum[2], yang dapat membantu mengurangi emisi gas buang yang menjadi polusi dari kendaraan bermotor[3]. Angkutan umum dapat mempercepat mobilitas penduduk, mengurangi kemacetan lalu lintas, dan meningkatkan taraf hidup penduduk[4]. Masyarakat yang bersedia memilih angkutan umum semakin banyak dengan keunggulan kenyamanan, keterjangkauan, dan aksesibilitas[5]. Layanan angkutan umum menghadapi lebih banyak tantangan[6] dan beberapa masalah yang secara bertahap muncul seiring dengan peningkatan pengguna

angkutan umum dan berbagai permintaan perjalanan[1].

Keberhasilan transportasi perkotaan didasarkan pada pemilihan desain yang optimal dan layanan sistem angkutan umum yang paling memenuhi[7], serta menyeimbangkan kebutuhan antara operator dan pelanggan[8]. Proses perencanaan angkutan umum perkotaan pada umumnya berkaitan dengan penyediaan tingkat layanan yang baik dengan biaya yang terjangkau bagi operator angkutan umum dan pengguna[9]. Aspek desain dan layanan dapat bervariasi untuk menghasilkan solusi optimal pada lingkungan perkotaan tertentu dan kebutuhan layanan. Bus Rapid Transit (BRT) menjadi transportasi umum bus yang semakin banyak digunakan di seluruh dunia[10].

BRT dapat digunakan masyarakat luas dalam menunjang mobilitas yang merupakan salah satu bagian dari integrasi sistem transportasi umum[11]. BRT pada suatu wilayah melayani beberapa trayek yang dalam satu trayek terdapat beberapa Halte. Setiap operasional BRT melayani sejumlah penumpang yang mungkin dapat terdiri dari pelajar, pekerja, bahkan wisatawan[12]. Data penumpang merupakan data penting yang dapat digunakan untuk perencanaan rute dan penyesuaian rute, serta melihat ketersediaan layanan yang diberikan [13]. Data penumpang dapat menjadi objek data mining yang dapat dimanfaatkan.

Load factor BRT menjadi metrik yang mengukur seberapa penuh bus selama operasi. Load factor biasanya dinyatakan sebagai rasio antara jumlah penumpang aktual yang diangkut dan kapasitas maksimal bus[14]. Load factor yang optimal penting untuk memastikan layanan BRT efisien dan memenuhi kebutuhan penumpang dengan baik. Load factor yang baik memastikan efisiensi operasional dan mengurangi biaya penumpang. Informasi tentang load factor membantu dalam perencanaan rute dan jadwal untuk menyesuaikan frekuensi layanan sesuai dengan permintaan penumpang, menghindari bus terlalu penuh atau terlalu kosong[15]. Bus yang beroperasi dengan load factor rendah dapat mengakibatkan pendapatan yang tidak mencukupi untuk menutupi biaya operasional. Permintaan penumpang yang sangat bervariasi membuat sulit mempertahankan load factor yang stabil dan optimal[16]. Beberapa rute membutuhkan penyesuaian jadwal dan frekuensi yang tepat untuk mengoptimalkan load factor di semua rute. Pengumpulan data yang akurat dan analisis prediktif yang andal diperlukan untuk mengelola load factor secara efektif[17]. Teknologi dan metode analisis data yang canggih sangat penting dalam mengatasi permasalahan tersebut[18].

Klasifikasi load factor merupakan pendekatan yang digunakan untuk mengelompokkan tingkat kepadatan penumpang bus berdasarkan beberapa kategori. Kemudahan analisis dan pengambilan keputusan yang lebih efektif menjadi tujuan klasifikasi[19]. Operator BRT dapat mengidentifikasi pola permintaan penumpang yang berbeda pada berbagai waktu dan rute dengan menggunakan klasifikasi load factor. Load factor dipahami melalui klasifikasi membantu operator BRT untuk menghindari situasi overcrowding dan mengurangi[20]. Klasifikasi load factor menyediakan data yang lebih terstruktur dan mudah diinterpretasikan analisis untuk perencanaan jangka panjang, pengembangan rute baru, dan penjadwalan bus. Data yang tidak lengkap atau tidak akurat dapat menghambat proses klasifikasi dan analisis load factor yang tepat. Implementasi teknologi untuk mengumpulkan dan

menganalisis data load factor menjadi tantangan bagi beberapa operator BRT[21].

Data historis dan real-time dikumpulkan tentang jumlah penumpang, waktu perjalanan, rute, dan faktor lainnya yang mempengaruhi load factor. Teknologi seperti sensor penumpang dan sistem tiket elektronik dapat membantu dalam pengumpulan data yang lebih akurat[22]. Pembersihan dan persiapan data untuk analisis dan penanganan nilai yang hilang, normalisasi, dan transformasi fitur yang relevan. Algoritma machine learning dapat digunakan untuk mengklasifikasikan load factor berdasarkan fitur-fitur yang telah dikumpulkan[23]. Evaluasi kinerja model klasifikasi dengan metrik seperti akurasi, precision, recall, dan F1 score untuk memastikan kehandalan model. Pendekatan berbasis data dan algoritma machine learning digunakan untuk mengoptimalkan sumber daya, meningkatkan kenyamanan penumpang, dan memastikan keberlanjutan sistem[24].

Parameter algoritma machine learning telah dilakukan pada klasifikasi mengenai penyakit diabetes pada pasien. Performa pengklasifikasian dapat ditingkatkan dengan melakukan tuning hyperparameter dengan menggunakan algoritma klasifikasi K-Nearest Neighbors, Decision Tree, Random Forest, dan Support vector. Klasifikasi terbaik diperoleh melalui algoritma Random Forest dengan nilai akurasi 88.61%[25]. Algoritma supervised learning seperti Logistic Regression, Support Vector Classifier (SVC), K-Nearest Neighbors (KNN), Gaussian Naive Bayes, Decision Tree, Random Forest, Gradient Boosting, dan Linear Discriminant Analysis (LDA) digunakan untuk klasifikasi rekrutmen kampus. Dataset yang digunakan yaitu campus recruitment dataset. Hyperparameter tuning pada Linear Discriminant Analysis (LDA) mengalami peningkatan akurasi yang lebih baik dibandingkan dengan algoritma lainnya dengan nilai 87.61%[26].

Load factor menjadi acuan atau indikator BRT Transjatin untuk menilai efisiensi dan menentukan kelayakan layanan transportasi yang tersedia. Biaya operasional BRT Transjatin juga dapat diacu dari load factor. Klasifikasi load factor rute bus BRT diusulkan dengan tuning parameter berdasarkan 2 jenis matrix(Minkowski dan Euclidean) terhadap algoritma KNN dan meningkatkan nilai akurasi. Klasifikasi yang dihasilkan dapat menjadi bagian yang dapat digunakan untuk mengukur jumlah armada yang beroperasi pada rute tersebut sudah cukup, kurang, atau melebihi kebutuhannya.

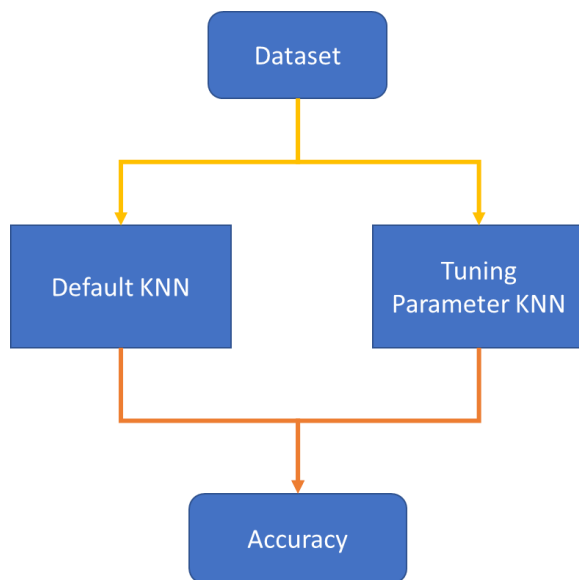
2. Metode Penelitian

Klasifikasi menjadi fungsi pengelompokan yang menjelaskan atau membedakan kelas data untuk

memperkirakan kelas suatu objek yang tidak diketahui labelnya atau membagi sesuatu menurut kelasnya [27]. Klasifikasi merupakan proses pencarian kelas data untuk memperkirakan kelas suatu objek yang tidak diketahui labelnya[28]. Langkah KNN perlu disertai dengan informasi data latih untuk menentukan klasifikasi objek hingga jarak terdekat. Hasil prediksi dengan metode KNN diperoleh dengan mengklasifikasikan jarak terdekat dari tetangga [29]. KNN mencari jarak terdekat antara informasi yang akan dievaluasi dengan nilai K dari tetangga pada data latih [30](Persamaan 1).

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Scaling data terhadap dataset yang digunakan tidak dilakukan. Algoritma KNN akan digunakan aturan algoritma majority classification rule. Data yang digunakan yaitu data trayek Koridor 1 Transjatin dengan rute keberangkatan halte hingga halte dan sebaliknya sebanyak 148 data. Program dibuat menggunakan Bahasa pemrograman Phyton melalui aplikasi jupyterlab. Perbandingan antara data latih dan data uji yaitu 75:25. Klasifikasi yang dilakukan dengan 2 keadaan. Keadaan pertama yaitu dataset yang diolah menggunakan algoritma KNN secara default. Keadaan kedua yaitu dataset yang diolah menggunakan algoritma KNN dengan tuning parameter didalamnya. Tuning dilakukan terhadap matrix algoritma KNN untuk mendapatkan hasil klasifikasi yang lebih baik. Pada akhirnya akan dilakukan perbandingan hasil akurasi klasifikasi terhadap dua keadaan tersebut(Gambar 1).



Gambar 1. Alur Penelitian

3. Hasil dan Pembahasan

Dataset yang digunakan memiliki fitur data penumpang yang naik dan penumpang turun, serta label kategori yaitu 1 dan 2. Kategori 1 menunjukkan tidak padatnya penumpang yang naik kendaraan umum

serta tidak terpenuhinya biaya operasional kendaraan. Kategori 2 menunjukkan kepadatan penumpang yang cukup padat dan terpenuhinya biaya operasional. Penumpang naik yang terbanyak yaitu 83, sedangkan yang terendah sebanyak 19. Penumpang yang turun ada 4 yang 0, sedangkan ada satu sebanyak 5. Kategori 1 ada sebanyak 4, sedangkan kategori 2 hanya ada 1(Tabel 1).

Tabel 1. Dataset

	Penumpang Naik	Penumpang Turun	Kategori
0	31	0	1
1	19	0	1
2	50	0	1
3	83	0	2
4	51	5	1

Pemilihan dan persiapan fitur dataset menjadi langkah penting dalam melakukan klasifikasi dengan algoritma KNN. Fitur-fitur yang tepat dan terproses dengan baik akan membantu model KNN untuk membuat klasifikasi yang akurat dan andal. Fitur penumpang naik dan penumpang turun menjadi pilihan dikarenakan ketersediaan dataset yang dimiliki koridor BRT Transjatin. Klasifikasi berdasarkan ketidakpadatan penumpang(Kategori 1) dan kepadatan penumpang(Kategori 2). Kepadatan penumpang dapat didapatkan dari jumlah penumpang yang naik dan turun. Hal tersebut menjadikan modal utama dalam melakukan klasifikasi load factor BRT.

Klasifikasi menggunakan algoritma KNN memberikan hasil akurasi yang cukup baik. Terlihat dari awal percobaan sudah didapatkan naik akurasi sebesar 89.19%. Tuning parameter dilakukan dengan matrix diubah menjadi Euclidean mendapatkan peningkatan nilai akurasi menjadi 97.00%. Peningkatan akurasi terjadi sebesar 7.81%(Tabel 2).

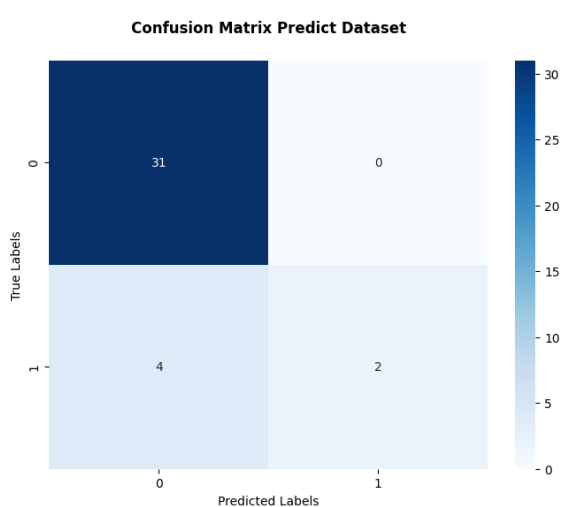
Tabel 2. Hasil Akurasi

Keadaan	Parameter		Akurasi (%)
	Nilai K	Matrix	
Default KNN	5	Minkowski	89.19
Tuning KNN	5	Euclidean	97.00
Peningkatan			7.81

Matrik evaluasi yang sering digunakan untuk menilai kinerja model klasifikasi menggunakan akurasi. Akurasi mengukur proporsi prediksi yang benar dari total prediksi yang dilakukan oleh model klasifikasi menggunakan algoritma KNN. Akurasi memberikan gambaran umum seberapa baik model bekerja pada dataset pengujian. Nilai akurasi yang tinggi menunjukkan model mampu mengklasifikasikan dengan benar sebagian besar instance dalam dataset pengujian. Akurasi bukan satu-satunya matrik yang harus dipertimbangkan, terutama jika dataset tidak seimbang. Perbandingan untuk mengetahui peningkatan nilai akurasi menjadi tumpuan utama

untuk menentukan model klasifikasi load factor BRT berdasarkan tuning parameter pada algoritma KNN.

Pada keadaan pertama dilakukan proses klasifikasi menggunakan KNN dengan parameter *default* yang dimilikinya, yaitu menggunakan nilai $K=5$ dan *matrix* minkowski. Hasil pengujian didapatkan nilai akurasi yang dihasilkan sebesar 89.19%. Confusion matrix terdapat 31 nilai *true positive* yang berarti sampel diprediksi dengan benar sebagai positif. 2 nilai *true negative* yang berarti sampel diprediksi dengan benar sebagai negatif. 4 nilai *false positive* yang berarti sampel yang diprediksi salah sebagai positif. 0 nilai *false negative* yang berarti sampel yang salah diprediksi sebagai negative(Gambar 2).



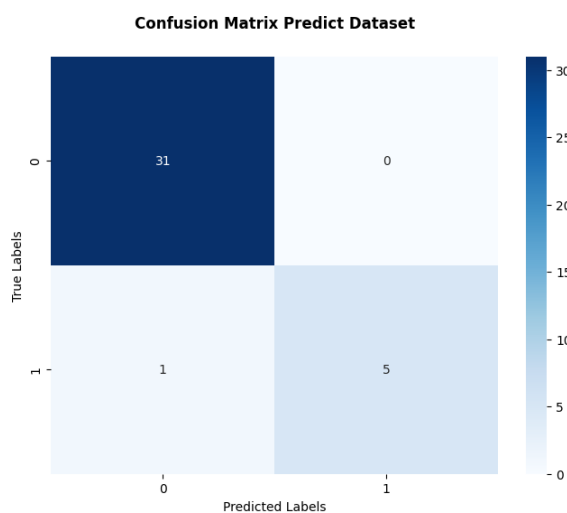
Gambar 2. Confusion Matrix *Default* KNN

Confusion matrix menjadi alat yang sangat berguna untuk mengevaluasi kinerja model klasifikasi KNN. Confusion matrix memberikan gambaran yang lebih rinci tentang model untuk mengklasifikasikan instance dari berbagai kelas. Confusion matrix berupa tabel yang digunakan untuk menilai kinerja algoritma klasifikasi. Tabel akan membandingkan prediksi model dengan label sebenarnya dan terdiri dari empat komponen utama untuk setiap kelas dalam klasifikasi biner. Confusion matrix memberikan wawasan yang lebih mendalam dibandingkan hanya dengan menggunakan akurasi, karena menunjukkan kesalahan spesifik yang dilakukan model. Confusion matrix default KNN memiliki nilai *true positive* yang tinggi dan memiliki 0 untuk *false negative*. Hal tersebut berarti model klasifikasi load factor BRT sudah cukup baik.

Tuning parameter algoritma KNN dengan nilai K dan *matrix* dari algoritma KNN. Nilai K terbaik dan *matrix* terbaik ditentukan untuk menghasilkan nilai akurasi tertinggi yang bisa didapatkan. Nilai akurasi yang didapatkan yaitu sebesar 97 % dengan parameter nilai $k=5$ dan *matrix* Euclidean. 31 nilai *true positive* yang berarti sampel diprediksi dengan benar sebagai positif.

5 nilai *true negative* yang berarti sampel diprediksi dengan benar sebagai negative. 1 nilai *false positive* yang berarti sampel yang diprediksi salah sebagai positif. 0 nilai *false negative* yang berarti sampel yang salah diprediksi sebagai negatif. Tuning parameter yang dilakukan menghasilkan nilai akurasi yang lebih baik berdasarkan nilai *true negative* yang lebih besar dari keadaan sebelumnya(

Gambar 3).




Gambar 3. Confusion Matrix *Tuning* KNN

Gambaran rinci kesalahan yang dibuat model klasifikasi dengan algoritma KNN dievaluasi dengan confusion matrix. Wawasan lebih dalam tentang kinerja model dan area yang perlu diperbaiki dilakukan dengan menghitung dan menganalisis confusion matrix. Perhitungan metrik evaluasi tambahan dapat dilakukan untuk mendapatkan pemahaman yang lebih menyeluruh tentang performa model klasifikasi. Confusion matrix tuning parameter KNN terdapat 2 perubahan yang terjadi dibandingkan default KNN. Perubahan tersebut yaitu terjadi peningkatan pada *true negative* dan penurunan pada *false positive*. Hal tersebut menjadi indikator terhadap peningkatan nilai akurasi pada model klasifikasi load factor BRT.

Identifikasi pola tergambar melalui diagram scatter matrix. Penumpang naik dan penumpang turun memiliki titik-titik yang tersebar secara acak tanpa pola yang jelas. Beberapa titik terjadi tumpang tindih dan menyebar, sehingga pola titik tidak dapat membentuk pola yang jelas. Hal tersebut menunjukkan tidak ada hubungan antara variable penumpang naik dan penumpang turun. Kategori dengan penumpang naik dan penumpang turun memiliki titik-titik membentuk garis lurus pada 2 klasifikasi yaitu kategori 1 dan 2. Hal tersebut menunjukkan terdapat hubungan linier positif atau negatif. Kategori 1 dan 2 menjadi fitur yang sangat baik untuk membedakan penumpang naik dan

penumpang turun. Kategori 1 memiliki titik yang lebih banyak dibandingkan dengan kategori 2. Hal tersebut berarti kategori 1 memiliki nilai yang lebih tinggi dibandingkan dengan kategori 2 (Gambar 4).



Gambar 4. Scatter Matrix Klasifikasi KNN

Scatter matrix atau pair plot menjadi visualisasi untuk memahami hubungan antara berbagai fitur klasifikasi. Scatter matrix menampilkan scatter plot untuk setiap pasangan fitur klasifikasi dan histogram atau plot distribusi untuk masing-masing fitur di sepanjang diagonal. Hal tersebut dapat membantu memahami korelasi, distribusi, dan potensi outlier data dengan algoritma KNN yang bergantung pada jarak antar data poin. Scatter matrix menunjukkan seberapa baik kelas yang berbeda dapat dipisahkan berdasarkan fitur yang diberikan. Fitur menunjukkan pemisahan kelas yang baik dalam scatter matrix kemungkinan besar akan memberikan kinerja yang lebih baik dalam KNN. Interaksi fitur dan keterkaitan kelas target dapat dipahami. Scatter matrix dalam klasifikasi dengan KNN membantu dalam memilih fitur yang relevan, mengidentifikasi outlier, dan memahami distribusi kelas yang berbeda pada ruang fitur. Keputusan yang lebih baik tentang preprocessing data dan fitur yang digunakan KNN dapat digunakan dengan scatter matrix. Hal tersebut dapat meningkatkan kinerja model klasifikasi load factor BRT dengan menggunakan algoritma KNN. Scatter matrix dapat memberikan gambaran yang lebih komprehensif tentang kinerja model KNN untuk klasifikasi load factor BRT dengan fitur yang paling informatif dan relevan. Relevansi fitur kategori 1 dan 2 mempunyai kesesuaian untuk melakukan klasifikasi load factor BRT dengan

algoritma KNN. Kategori 1 memiliki kelas yang lebih tinggi dibandingkan kategori 2 untuk penumpang naik dan penumpang turun.

Klasifikasi load factor Bus Rapid Transit (BRT) menggunakan algoritma K-Nearest Neighbors (KNN) menemukan beberapa hal penting terkait dengan efektivitas model dan tuning parameter yang digunakan. Model KNN menggunakan dua jenis matriks jarak (Euclidean dan Minkowski) dengan tuning parameter pada matriks Euclidean memberikan peningkatan kinerja model sebesar 7.81% dibandingkan dengan matriks Minkowski. Matriks Euclidean lebih sederhana dan secara langsung mengukur jarak linier antar titik data, sedangkan Minkowski lebih fleksibel tetapi juga lebih kompleks. Kesederhanaan Euclidean ternyata menjadikannya lebih efektif. Nilai K yang digunakan yaitu 5 yang berarti model mempertimbangkan 5 tetangga terdekat untuk menentukan klasifikasi load factor. Pemilihan nilai K yang tepat sangat penting untuk keseimbangan antara bias dan varians. Tuning parameter pada matriks Euclidean meningkatkan jumlah prediksi true negative. Hal tersebut berarti model lebih akurat dalam mengidentifikasi kondisi bus tidak penuh (kategori negatif). Penurunan false positive menunjukkan model semakin jarang salah mengklasifikasikan situasi bus tidak penuh sebagai penuh (kategori positif). Hal tersebut berkontribusi langsung pada peningkatan akurasi model.

Peningkatan pada true negative dan penurunan pada false positive menjadikan secara keseluruhan akurasi model mengalami peningkatan. Akurasi yang lebih tinggi berarti model lebih andal dalam memprediksi load factor bus. Penumpang naik dan penumpang turun dikategorikan dalam dua kategori berdasarkan tingkat kepadatan. Kategori 1 memiliki kelas yang lebih tinggi dibandingkan dengan kategori 2 yang menunjukkan kategori 1 merepresentasikan kondisi dengan lebih banyak penumpang. Perbedaan antara kategori 1 dan kategori 2 dipahami untuk membantu dalam menginterpretasikan hasil prediksi dan mengambil tindakan yang tepat. Operator BRT dapat mengoptimalkan jadwal dan rute bus untuk menghindari overcrowding atau underutilization dan meningkatkan efisiensi operasional dengan menggunakan model yang lebih akurat. Peningkatan akurasi dalam prediksi load factor membantu dalam menjaga kenyamanan penumpang dengan menghindari situasi bus yang terlalu penuh atau terlalu kosong. Manajemen BRT dapat menggunakan hal tersebut untuk mendukung pengambilan Keputusan yang lebih baik dan berbasis data dan operator dapat merespon perubahan permintaan penumpang dengan lebih efektif.

Klasifikasi load factor BRT menggunakan algoritma KNN dengan tuning parameter dengan menggunakan matriks jarak Euclidean telah terbukti meningkatkan akurasi model secara signifikan. Evaluasi model menunjukkan peningkatan dalam prediksi true negative dan penurunan false positive yang secara keseluruhan meningkatkan kinerja klasifikasi load factor. Perbedaan antara kategori penumpang naik dan turun lebih lanjut memperkuat kemampuan model untuk membuat prediksi yang tepat, serta memberikan manfaat besar dalam optimasi operasional dan peningkatan kenyamanan penumpang.

4. Kesimpulan

Klasifikasi load factor BRT menggunakan algoritma KNN berdasarkan kategori 1 dan 2 pada penumpang naik dan penumpang turun mengalami kenaikan 7.81% dengan tuning parameter pada matrix Euclidean dibandingkan matrix Minkowski. Nilai K yang digunakan yaitu 5. Confusion matrix tuning parameter KNN terdapat 2 perubahan yaitu peningkatan pada true negative dan penurunan pada false positive yang berarti terjadi peningkatan nilai akurasi pada model klasifikasi load factor BRT. Kategori 1 memiliki kelas yang lebih tinggi dibandingkan kategori 2 untuk penumpang naik dan penumpang turun.

Daftar Rujukan

- [1] L. Wang *et al.*, "Identification and Classification of Bus and Subway Passenger Travel Patterns in Beijing Using Transit Smart Card Data," *J Adv Transp*, vol. 2023, 2023, doi: 10.1155/2023/6529819.
- [2] D. R. R. Cabrera-Moya, "Economías de aglomeración, sistemas de transporte público masivo tipo BRT (Bus Rapid Transit) y decisiones de ubicación geográfica de empresas," *urbe. Revista Brasileira de Gestão Urbana*, vol. 13, 2021, doi: 10.1590/2175-3369.013.e20190217.
- [3] M. Chester, S. Pincetl, Z. Elizabeth, W. Eisenstein, and J. Matute, "Infrastructure and automobile shifts: Positioning transit to reduce life-cycle environmental impacts for urban sustainability goals," *Environmental Research Letters*, vol. 8, no. 1, 2013, doi: 10.1088/1748-9326/8/1/015041.
- [4] A. Olowosegun, D. Moyo, and D. Gopinath, "Multicriteria evaluation of the quality of service of informal public transport: An empirical evidence from Ibadan, Nigeria," *Case Stud Transp Policy*, vol. 9, no. 4, 2021, doi: 10.1016/j.cstp.2021.08.002.
- [5] Y. Sun and Y. Cui, "Evaluating the coordinated development of economic, social and environmental benefits of urban public transportation infrastructure: Case study of four Chinese autonomous municipalities," *Transp Policy (Oxf)*, vol. 66, 2018, doi: 10.1016/j.tranpol.2018.02.006.
- [6] V. Varabuntoonvit, K. Boonyarith, P. Pakornkarn, P. Pichetwanit, and W. Sittipong, "Sustainable efficiency indicator for urban transportation: Case study of public bus and rapid transit systems in <sc>Bangkok</sc>," *Environ Prog Sustain Energy*, vol. 42, no. 4, Jul. 2023, doi: 10.1002/ep.14154.
- [7] A. L. Kelkar and K. Kulkarni, "Route Profitability Prediction for Public Bus Transportation System," in *2022 5th International Conference on Advances in Science and Technology (ICAST)*, IEEE, Dec. 2022, pp. 428–430. doi: 10.1109/ICAST55766.2022.10039610.
- [8] T. Bubalo, M. Rajsman, and P. Škorput, "Methodological Approach for Evaluation and Improvement of Quality Transport Service in Public Road Passenger Transport," *Tehnicki vjesnik - Technical Gazette*, vol. 29, no. 1, Feb. 2022, doi: 10.17559/TV-20201031104641.
- [9] I. Moser *et al.*, "A methodology for empirically evaluating passenger counting technologies in public transport," in *Australasian Transport Research Forum, ATRF 2019 - Proceedings*, 2019. Accessed: Dec. 05, 2023. [Online]. Available: https://australasiantransportresearchforum.org.au/wp-content/uploads/2022/03/ATRF2019_resubmission_48.pdf
- [10] S. C. Wirasinghe, L. Kattan, M. M. Rahman, J. Hubbell, R. Thilakarathne, and S. Anowar, "Bus rapid transit - a review," *International Journal of Urban Sciences*, vol. 17, no. 1, 2013. doi: 10.1080/12265934.2013.777514.
- [11] J. Singh, H. K. Chaudhary, and A. Malik, "A Case Study on Indore BRTS with Reference to Other Indian Cities," *Int J Res Appl Sci Eng Technol*, vol. 10, no. 10, pp. 196–203, Oct. 2022, doi: 10.22214/ijraset.2022.46976.
- [12] G. Tobias Portis, A. Mota dos Santos, and F. Gioppo Nunes, "Influência da Infraestrutura de Transportes sobre a Temperatura de Superfície em um corredor BRT, na cidade de Goiânia/GO," *Ateliê Geográfico*, vol. 16, no. 1, pp. 143–164, Apr. 2022, doi: 10.5216/ag.v16i1.71849.
- [13] J. Wang, Y. Chen, L. Mao, R. Yang, D. Li, and B. Chen, "Public Transport Passengers' Classification and Path Choice Characteristics Analysis by Using C&RT Model in Beijing," in *IOP Conference Series: Materials Science and Engineering*, 2019. doi: 10.1088/1757-899X/688/4/044018.
- [14] P. Song, W. Song, A. Meng, and H. Li, "Adaptive Equivalent Factor-Based Energy Management Strategy for Plug-In Hybrid Electric Buses Considering Passenger Load Variations," *Energies (Basel)*, vol. 17, no. 6, p. 1283, Mar. 2024, doi: 10.3390/en17061283.
- [15] X. Shen and S. Feng, "How public transport subsidy policies in China affect the average passenger load factor of a bus line," *Research in Transportation Business & Management*, vol. 36, p. 100526, Sep. 2020, doi: 10.1016/j.rtbm.2020.100526.
- [16] B. Z. Malik, Z. ur Rehman, A. H. Khan, and W. Akram, "Investigating users' travel behaviours and perceptions of single-corridor BRT: Lessons from Lahore," *J Transp Geogr*, vol. 91, p. 102942, Feb. 2021, doi: 10.1016/j.jtrangeo.2020.102942.
- [17] V. V. R. Akhil and B. Ramesh, "Feasibility Studies and Performance Evaluation of BRTS in Rajahmundry and Kakinada Corridor," *Int J Res Appl Sci Eng Technol*, vol. 11, no. 4, pp. 4571–4577, Apr. 2023, doi: 10.22214/ijraset.2023.51072.
- [18] R. Dantas, J. Dantas, C. Melo, and P. Maciel, "Performance evaluation in BRT systems: An analysis to predict the BRT systems planning," *Case Stud Transp Policy*, vol. 9, no. 3, pp. 1141–1150, Sep. 2021, doi: 10.1016/j.cstp.2021.06.002.
- [19] C. A. Sakurai, C. F. Fontana, B. De Carvalho Negrão, and A. G. Da Silva Andrade, "System Functionalities of Its for BRT," *International Journal of Computational and Applied Mathematics & Computer Science*, vol. 2, pp. 18–25, Jun. 2022, doi: 10.37394/232028.2022.2.4.
- [20] M. Admad, S. Saeed, A. Babar, and F. Ullah, "Socio-cultural and Economic Impacts of BRT Peshawar," *International Journal of Emerging Trends in Engineering Research*, vol. 9, no. 6, pp. 759–764, Jun. 2021, doi: 10.30534/ijeter/2021/22962021.
- [21] H. Thevadass *et al.*, "A Review on BRT Scoring System for Malaysia Practice," *Civil Engineering and Architecture*, vol. 9, no. 2, pp. 410–419, Mar. 2021, doi: 10.13189/cea.2021.090214.
- [22] C. F. Fontana, C. A. Sakurai, C. L. Marte, J. R. Cardoso, and A. G. Da Silva Andrade, "Power Line Communication as Alternative for Data Communication Channel for BRT," *EARTH SCIENCES AND HUMAN CONSTRUCTIONS*, vol. 2, pp. 60–67, Mar. 2022, doi: 10.37394/232024.2022.2.9.
- [23] A. M. Santos and A. G. De Oliveira, "A importância da mobilidade urbana: implantação da primeira linha do BRT em Salvador / The importance of urban mobility: implementation of the first line of BRT in Salvador," *Brazilian Applied Science Review*, vol. 5, no. 4, pp. 1951–1969, Aug. 2021, doi: 10.34115/basrv5n4-017.
- [24] Hiroaki Inokuchi, "Combinations of Transportation Policies to Promote BRT Usage Using Artificial Society Model," *Journal*

-
- of *Traffic and Transportation Engineering*, vol. 12, no. 1, Feb. 2024, doi: 10.17265/2328-2142/2024.01.001.
- [25] S. C. Gupta and N. Goel, "Predictive Modeling and Analytics for Diabetes using Hyperparameter tuned Machine Learning Techniques," *Procedia Comput Sci*, vol. 218, pp. 1257–1269, 2023, doi: <https://doi.org/10.1016/j.procs.2023.01.104>.
- [26] D. Muhajir, M. Akbar, A. Bagaskara, and R. Vinarti, "Improving classification algorithm on education dataset using hyperparameter tuning," *Procedia Comput Sci*, vol. 197, pp. 538–544, 2022, doi: <https://doi.org/10.1016/j.procs.2021.12.171>.
- [27] A. Yazdinejad, A. Dehghantanha, R. M. Parizi, and G. Epiphaniou, "An optimized fuzzy deep learning model for data classification based on NSGA-II," *Neurocomputing*, vol. 522, 2023, doi: 10.1016/j.neucom.2022.12.027.
- [28] C. Singla and C. Jindal, "Comparison of Various Classification Models Using Machine Learning to Predict Mobile Phones Price Range," in *Convergence of Cloud with AI for Big Data Analytics: Foundations and Innovation*, 2024. doi: 10.1002/9781119905233.ch17.
- [29] S. Adhikary and S. Banerjee, "Introduction to Distributed Nearest Hash: On Further Optimizing Cloud Based Distributed kNN Variant," in *Procedia Computer Science*, 2022. doi: 10.1016/j.procs.2023.01.135.
- [30] A. Ali, M. Hamraz, N. Gul, D. M. Khan, S. Aldahmani, and Z. Khan, "A k nearest neighbour ensemble via extended neighbourhood rule and feature subsets," *Pattern Recognit*, vol. 142, 2023, doi: 10.1016/j.patcog.2023.109641.