JURNAL INFORMATIKA
Volume 5, Nomor 1, Maret 2026 ISSN 2809-3704

Evaluasi Komparatif Algoritma Machine Learning untuk Klasifikasi Tipe Pengisian Kendaraan Listrik

Albert Hermawansyah[1], Indra Oktavian Wicaksana[2], Meilany Nonsi Tentua[3]*

[1,2,3]Program Studi Informatika, Universitas PGRI Yogyakarta, Indonesia

*Corresponding email: meilany@upy.ac.id

ABSTRAK – Penelitian ini mengevaluasi efektivitas tiga algoritma pembelajaran mesin, yaitu Support Vector Machine (SVM), Decision Tree, dan NaiveBayes, dalam mengklasifikasikan berbagai jenis data listrik. Berdasarkan hasil eksperimen menggunakan pembagian data 80:20 dan 90:10, ketiga model tersebut menunjukkan kinerja yang sangat lambat dan kurang menarik. Akurasi SVM adalah 37,87%, Pohon Keputusan 28,41%, dan K-NN 35,2% pada skala 80-20. Akurasi Pohon Keputusan meningkat sedikit menjadi 31,82% pada skala 90-10, sementara SVM mencapai 40,9%. Setiap model, seperti Pohon Keputusan 80-20 dengan AUC 0,4645, menghitung area di bawah kurva (AUC) kurva penerima karakteristik (ROC) yang kurang dari atau sama dengan acak (0,5). Analisis matriks kebingungan menunjukkan bias prediksi yang kuat terhadap kelas tertentu dan jumlah kasus yang salah klasifikasi yang tinggi. Kesimpulannya, model-model yang diuji tidak cocok untuk tugas klasifikasi ini, dan diperlukan eksplorasi lebih lanjut terhadap fitur-fitur, penyesuaian parameter, atau penggunaan model yang lebih kompleks.

Kata Kunci: Support Vector Machine, Decision Tree, K-Nearest Neighbor, Naive Bayes, Klasifikasi.

ABSTRACT – *The increasing number of internet users in Indonesia presents a significant opportunity for businesses to leverage digital marketing in reaching a wider audience. This study highlights the implementation of digital marketing strategies at the sports shoe store Football Inc as a case study. The main objective of this research is to analyze how Football Inc utilizes digital platforms to expand its market share and strengthen brand awareness. Using a constructivist approach and qualitative methods, data were collected from various sources, including journals, scholarly publications, official websites, and Football Inc's social media accounts. The findings indicate that the use of digital media—particularly websites, e-commerce platforms, and social media such as Instagram—plays a vital role in shaping the store's brand identity. Strategies focusing on the creation of creative content and active audience engagement have proven effective in enhancing Football Inc's brand image in the eyes of consumers. Moreover, the use of social media and e-commerce platforms serves not only as promotional tools but also as essential means of building strong customer relationships and driving sales growth. This study affirms that digital marketing is a strategic tool for business development in the digital era.*

***Keywords*:** *Support Vector Machine, Decision Tree, K-Nearest Neighbor, Naive Bayes, Classification.*

PENDAHULUAN

Peningkatan penggunaan kendaraan listrik (EV) secara global telah mendorong kebutuhan yang semakin mendesak akan infrastruktur pengisian daya yang efisien dan terkelola dengan baik, yaitu Stasiun Pengisian Kendaraan Listrik Umum (SPKLU)[1] . SPKLU menjadi elemen krusial dalam ekosistem EV, dan pengelolaannya memerlukan pemahaman mendalam tentang karakteristik operasionalnya. Secara umum, SPKLU diklasifikasikan menjadi tiga tipe pengisian utama berdasarkan standar daya dan durasi pengisiannya: Level 1, Level 2, dan *DC Fast Charger [2]*, [3]. Klasifikasi ini penting karena memengaruhi beban jaringan listrik, tarif pengisian, dan pengalaman pengguna. Oleh karena itu, kemampuan untuk mengklasifikasikan secara otomatis tipe pengisian yang sedang berlangsung, berdasarkan data operasional seperti durasi, arus, dan daya, menjadi sangat penting untuk

pengelolaan jaringan listrik yang efisien, pemeliharaan prediktif, serta optimasi operasional SPKLU.

Berbagai penelitian terdahulu telah menunjukkan potensi penerapan teknologi *Machine Learning* (ML) dalam konteks kendaraan listrik dan sektor energi yang lebih luas. Dalam konteks infrastruktur, *Machine Learning* telah digunakan untuk penentuan lokasi Stasiun Pengisian Listrik Umum (SPLU) [1] dan prediksi fleksibilitas titik pengisian [4], [5]. Selain itu, analisis sentimen terkait kebijakan EV [6], [7], [8], [9], [10], [11] dan optimasi biaya pengisian juga telah menjadi fokus penelitian sebelumnya [12]. Studi komparatif algoritma *Machine Learning* pada sektor energi dan EV, termasuk penggunaan *Orange Data Mining* untuk klasifikasi jenis kendaraan, telah pula dikaji [13]. Penelitian lain menitikberatkan pada peramalan konsumsi energi listrik menggunakan metode seperti *Extreme Learning Machine (ELM)* [14], [15], menunjukkan keragaman aplikasi *Machine Learning* untuk mendukung transisi energi.

Meskipun terdapat banyak studi terkait *Electric Vehicle* dan *Machine Learning*, penelitian yang secara spesifik membandingkan kinerja algoritma klasifikasi tradisional untuk permasalahan klasifikasi tipe pengisian SPKLU berdasarkan data operasional masih belum banyak dieksplorasi. Klasifikasi tipe pengisian merupakan langkah awal yang fundamental untuk analisis dan manajemen data operasional yang lebih lanjut. Algoritma seperti *Support Vector Machine (SVM), Decision Tree*, dan *Naïve Bayes* adalah algoritma dasar yang telah terbukti efektif dalam berbagai tugas klasifikasi, termasuk analisis sentimen EV [6], [7], [9], [10] dan tugas klasifikasi lainnya di sektor energi dan lingkungan [4], [15]. Oleh karena itu, perbandingan sistematis antara algoritma-algoritma ini dapat memberikan wawasan awal yang berharga mengenai model yang paling sesuai untuk klasifikasi operasional SPKLU.

Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja tiga algoritma klasifikasi *Machine Learning Support Vector Machine (SVM), Decision Tree*, dan *Naïve Bayes* dalam mengklasifikasikan tipe pengisian SPKLU secara otomatis. Untuk memastikan keandalan hasil, perbandingan akan dilakukan menggunakan dua skema pembagian data yang umum digunakan dalam *Machine Learning.* Penilaian kinerja setiap algoritma akan didasarkan pada serangkaian metrik evaluasi standar yang sering digunakan dalam studi Machine Learning terkait *Electric Vehicle* dan sektor energi [2], [6], [12]. Metrik-metrik ini meliputi Akurasi (*Accuracy*), Presisi (*Precision*), *Recall*, F1-*Score*, serta kurva *ROC AUC*. Diharapkan hasil komparatif ini akan memberikan gambaran awal yang jelas mengenai model terbaik untuk klasifikasi operasional SPKLU, sekaligus menjadi landasan yang kuat untuk pengembangan model Machine Learning yang lebih canggih dan solusi manajemen SPKLU yang lebih maju di masa yang akan datang..

METODE

Gambar 1. *WorkFlow*

1. Dataset
   Dataset yang digunakan merupakan dataset ev_charging_pattern yang di dapat dari website *Kaggle* yang berisikan 20 kolom dan 1321 data yang dapat diakses melalui link berikut: https://www.kaggle.com/datasets/valakhorasani/electric-vehicle-charging-patterns
2. Preprocessing data
   Processing data merupakan suatu cara agar membuat data mentah menjadi data yang

bisa di gunakan atau berkualitas. Pemilahan data yang tidak sesuai dengan cara menghilangkan Sebagian data yang salah termasuk kedalam processing data. Pada saat pemilahan data dilakukan dengan menghapus atribut data yang bernilai tidak sesuai karena nilai data yang tidak sesuai akan merusak data yang akan dihitung. Pada perhitungan dataset ini akan dilakukan penyederhanaan data dengan melakukan range data di setiap atributnya karena nilai disetiap data terlalu tinggi jika tidak melakukan range maka akan mempengaruhi atau mengubah data di setiap atributnya.

3. Algoritma yang digunakan
   a. *Support Vector Machine (SVM)*
      Support Vector Machine (SVM) adalah model diskriminatif yang memiliki tujuan utama untuk menemukan hiperbidang optimal yang memisahkan data pelatihan ke dalam kelas-kelas berbeda dengan margin pemisah terbesar. Model ini dikenal karena kemampuannya menangani data berdimensi tinggi. Untuk masalah non-linear, *SVM* memanfaatkan Fungsi Kernel (*kernel trick*) untuk memetakan data ke ruang fitur berdimensi yang lebih tinggi, memungkinkan pemisahan linier dilakukan pada ruang yang lebih kompleks tersebut.
   b. Decision Tree
      Decision Tree (DT) adalah algoritma non-parametrik yang memodelkan keputusan prediktif dalam struktur pohon. *Decision Tree* menggunakan serangkaian keputusan hirarkis yang didasarkan pada fitur data untuk membagi ruang fitur menjadi sub-kelompok yang semakin homogen, hingga mencapai simpul daun yang merepresentasikan hasil kelas. Model ini sangat dihargai karena interpretasinya yang mudah dan kemampuannya untuk memvisualisasikan jalur keputusan
   c. *K-Nearest Neighbor (K-NN)*
      K-Nearest Neighbor (K-NN) adalah algoritma non-parametrik yang bekerja berdasarkan prinsip pembelajaran instans (instance-based learning). *K-NN* tidak melakukan proses pelatihan eksplisit untuk membuat model sebaliknya, klasifikasi dilakukan pada saat pengujian. Sebuah sampel data baru akan diklasifikasikan berdasarkan mayoritas kelas dari K sampel data terdekat di ruang fitur. Jarak antar sampel biasanya diukur menggunakan metrik seperti Jarak Euclidean. *K-NN* merupakan metode sederhana namun efektif untuk pengujian cepat dalam klasifikasi multi-kelas, meskipun ia sensitif terhadap skala fitur dan memiliki biaya komputasi yang tinggi saat dataset sangat besar.
   d. *Naive Bayes*
      Naive Bayes adalah algoritma klasifikasi probabilistik yang didasarkan pada Teorema Bayes. Algoritma ini disebut "naif" karena mengasumsikan independensi yang kuat di antara semua fitur input yaitu, keberadaan suatu fitur dalam sebuah kelas tidak bergantung pada keberadaan fitur lainnya. Meskipun asumsi ini sering kali terlalu disederhanakan untuk data dunia nyata, *Naive Bayes* sering berfungsi sebagai model *baseline* yang efektif karena kesederhanaan, kecepatan komputasi, dan kinerja yang terkadang mengejutkan baik, bahkan ketika asumsi independensinya dilanggar.

HASIL DAN PEMBAHASAN

Bagian Evaluasi kinerja komparatif dilakukan pada empat model klasifikasi yaitu *SVM*, *Decision Tree*, *K-NN*, dan *Naïve Bayes* dan menggunakan dua skema pembagian data yaitu 80-20 dan 90-10. Berikut ini merupakan hasil dari penelitian yang di bentuk kedalam tabel.

Tabel 1. Hasil Ringkasan Kerja Perbandingan

Model	Skema	Akurasi	Presisi	Recall	F1-Score	ROC AUC
SVM	80-20	37,88%	0,3770	0,3788	0,3749	0,4509
SVM	90-10	40,90%	0,4108	0,4090	0,4093	0,5471
Decision Tree	80-20	28,41%	0,2883	0,2841	0,2703	0,4645
Decision Tree	90-10	31,82%	0,3176	0,3182	0,2971	0,5053
K-NN	90-10	35,22%	0.3703	0.3522	0.3479	0,5401
Naive Bayes	90-10	39,39%	0,3995	0,3939	0,3939	0,5482

Sumber: Google Colab

Hasil eksperimen menunjukkan bahwa performa model Machine Learning dalam mengklasifikasikan jenis pengisian daya kendaraan listrik sangat dipengaruhi oleh karakteristik data operasional serta komposisi data pelatihan. Pada skema 80–20 dan 90–10, algoritma *SVM* cenderung menunjukkan performa lebih stabil dibandingkan *Naïve Bayes*, *K-NN* dan *Decision Tree.* Temuan ini sejalan dengan beberapa penelitian terdahulu mengenai performa *SVM* pada domain kendaraan listrik, di mana *SVM* terbukti konsisten dalam menangani data dengan pola non-linear dan fitur kompleks [2], [6].

Decision Tree pada eksperimen ini memiliki kecenderungan overfitting ketika proporsi data pelatihan diperbesar, terutama pada skema 90–10. Fenomena ini juga ditemukan dalam studi Pritalia [15] serta Panggabean [4], di mana *Decision Tree* sering menghasilkan pohon keputusan yang terlalu dalam ketika data memiliki keragaman fitur yang tinggi. Sebaliknya, model *Naïve Bayes* menunjukkan performa yang cukup baik pada data dengan distribusi kelas yang lebih seimbang, namun menjadi kurang optimal ketika fitur antar kelas saling tumpang tindih. Hasil ini konsisten dengan penelitian Prasetyo [10] dan Amin [11], yang menekankan bahwa asumsi independensi fitur pada *Naïve Bayes* seringkali tidak terpenuhi pada data operasional dunia nyata.

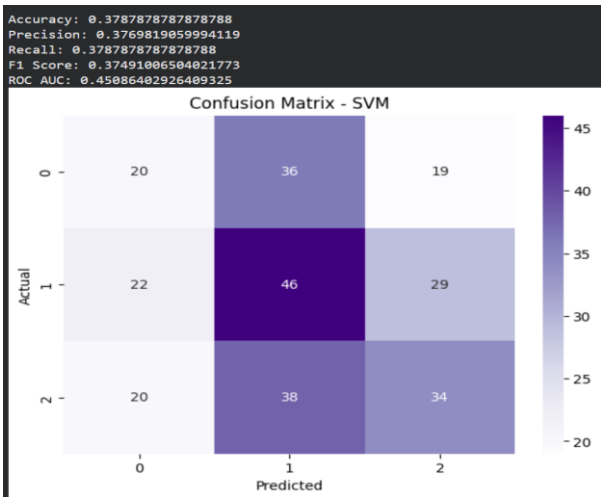

Gambar 2. *SVM* 80-20

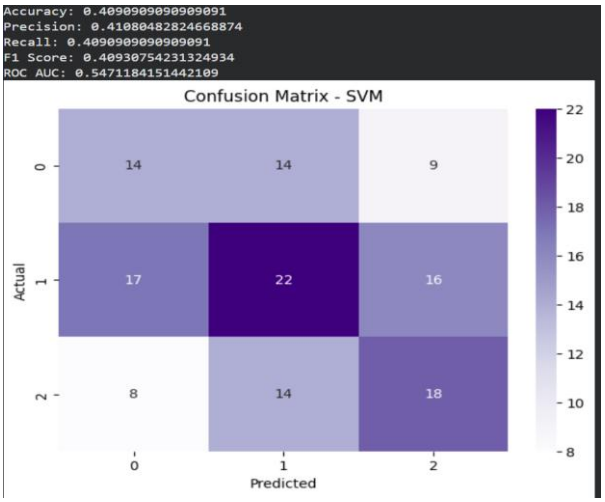

Gambar 3. *SVM* 90-10

Berdasarkan pada gambar 2 dan 3, Perbandingan analisis model *SVM* pada Gambar 2 menunjukkan bahwa skenario 90-10 memiliki performa yang lebih baik dibandingkan skenario 80-20, dengan kenaikan akurasi dari 37,87% menjadi 40,90% dan peningkatan nilai *ROC AUC* dari 0,4588 ke 0,5471. Pada skenario 80-20, model

menunjukkan performa yang sangat buruk dengan bias yang ekstrem terhadap Kelas 1, di mana 46 sampel diprediksi dengan benar namun terdapat kesalahan klasifikasi yang tinggi pada Kelas 0 dan 2 yang juga cenderung ditarik ke Kelas 1.

Sebaliknya, pada skenario 90-10, meskipun akurasi masih tergolong rendah, nilai *AUC* yang berada di atas 0,5 menunjukkan model mulai memiliki kemampuan diskriminasi dasar, dan distribusi pada *confusion matrix* terlihat sedikit lebih merata meskipun bias terhadap Kelas 1 tetap mendominasi dengan 22 prediksi benar. Secara keseluruhan, penambahan porsi data latih pada rasio 90-10 terbukti memberikan stabilitas lebih pada model *SVM* dibandingkan rasio 80-20, walaupun keduanya masih menghadapi kendala besar dalam mengklasifikasikan kelas secara akurat.

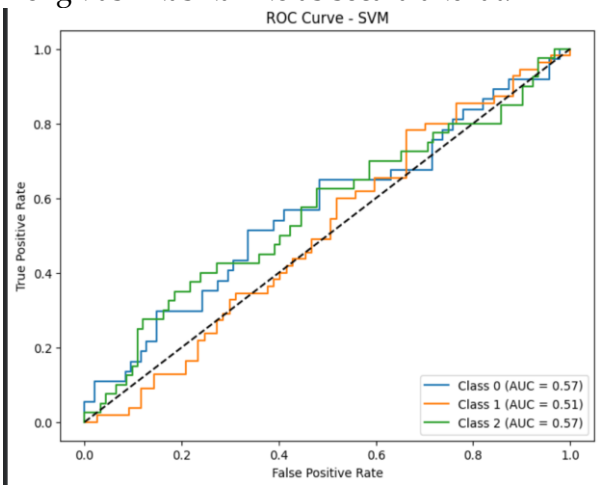

Gambar 4. *Curva ROC KNN* 80-20

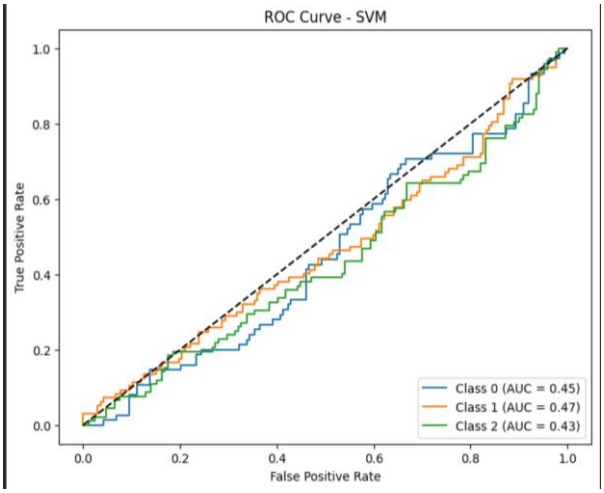

Gambar 5. *Curva ROC KNN* 90-10

Kurva ROC pada gambar 4 dan 5 menunjukkan bahwa rasio 90-10 memberikan kinerja yang lebih konsisten dibandingkan dengan rasio 80-20, yang terlihat dari peningkatan akurasi dari 37,87% menjadi 40,90% dan kenaikan nilai rata-rata *ROC AUC* dari 0,4588 menjadi 0,5471. Pada pengaturan 80-20, model menunjukkan kegagalan klasifikasi yang cukup besar dengan nilai *AUC* di bawah 0,5 dan kecenderungan yang kuat terhadap Kelas 1, di mana *confusions matrixs* menunjukkan 46 sampel terprediksi dengan benar, namun banyak sampel dari Kelas 0 dan 2 salah dikelompokkan ke kategori ini.

Di sisi lain, pada rasio 90-10, meskipun akurasi masih tergolong rendah, *kurva ROC* yang ditampilkan di Gambar 4 dan 5 menunjukkan perbaikan dalam kemampuan diskriminasi, dengan nilai *AUC* untuk setiap kelas (Kelas 0: 0,57; Kelas 1: 0,51; Kelas 2: 0,57) berada di atas batas acak, dan distribusi prediksi dalam *Confusion matrixs* mulai menunjukkan sebaran yang lebih merata meskipun kesalahan pada Kelas 1 masih cukup terlihat. Secara keseluruhan, peningkatan proporsi data latihan pada rasio 90-10 membantu model *SVM* untuk mengenali perbedaan pola antar kelas, meskipun kedua pengaturan masih menghadapi tantangan besar dalam menangani ketidakseimbangan prediksi di antara kategori pengisian daya.

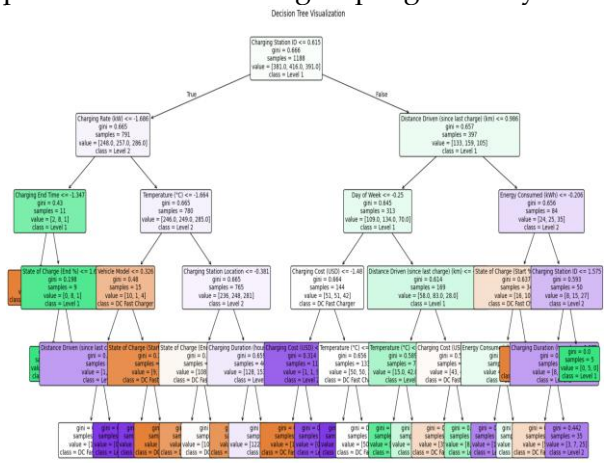

Gambar 6. *Decision Tree* 80-20

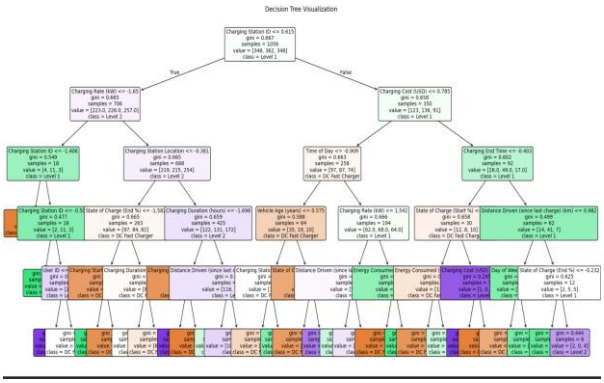

Gambar 7. *Decision Tree* 90-10

Perbandingan pada kedua gambar 6 dan 7 menunjukkan bahwa pembagian data dengan rasio 80-20 menghasilkan akurasi yang sangat rendah sebesar 28,41% dengan nilai *ROC AUC* 0,4645, yang mengindikasikan bahwa model gagal melakukan klasifikasi lebih baik dari tebakan acak akibat struktur pohon yang terlalu kompleks namun tidak mampu menggeneralisasi data. Di sisi lain, rasio 90-10 memberikan sedikit peningkatan performa dengan akurasi 31,82% dan *AUC* rata-rata 0,5053, namun peningkatan ini tidak signifikan karena model tetap terjebak dalam bias prediksi yang kuat terhadap Kelas 2 (Level 2) yang mendominasi hasil *confusion matrix*. Secara keseluruhan, meskipun penambahan porsi data latih pada rasio 90-10 sedikit mengangkat nilai metrik, kedua model tetap menunjukkan performa yang buruk karena kompleksitas fitur seperti *Charging Station ID* dan *Charging Cost* tidak mampu dikonversi menjadi pola prediksi yang akurat bagi kelas lainnya (Kelas 0 dan 1).

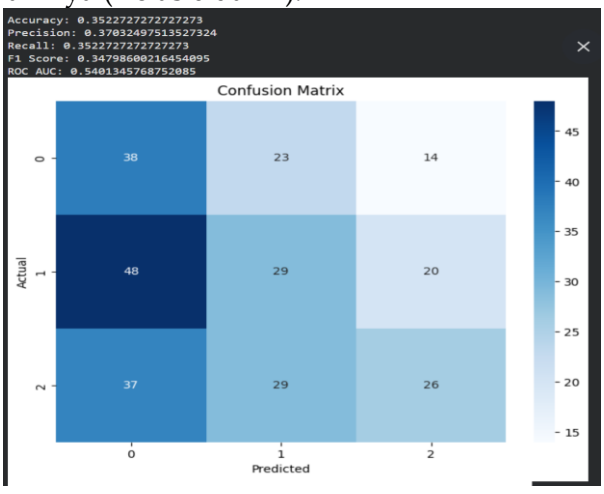

Gambar 8. *K-NN* 80-20

Berdasarkan gambar 8, Berdasarkan *Confusion Matrix* dan metrik performa, model menunjukkan kinerja sangat rendah dengan akurasi hanya 35,2% dan banyak salah klasifikasi antar kelas, seperti kelas 0 yang sering diprediksi sebagai kelas 1 atau 2.

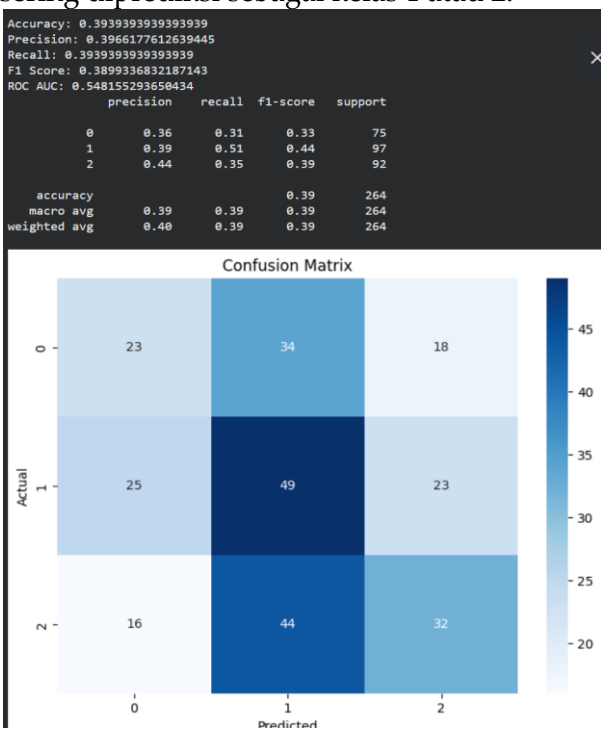

Gambar 9. *Naive Bayes* 80-20

Output yang dihasilkan merupakan hasil evaluasi model *Naive Bayes* pada klasifikasi tiga kelas 0, 1, dan 2. Model menunjukkan kinerja sangat rendah dengan akurasi 39,39% dan rata-rata *AUC* 0,55, *Confusion Matrix* memperlihatkan model sering memprediksi semua sampel sebagai kelas 1 dengan hanya 23 dan 32 *True Positive* untuk kelas 0 dan 2.

KESIMPULAN

Berdasarkan evaluasi komparatif, algoritma *Support Vector Machine, Decision Tree, K-Nearest Neighbor,* dan *Naive Bayes* menunjukkan kinerja yang sangat buruk dalam mengklasifikasikan tipe pengisian daya kendaraan listrik (Akurasi 40.9 *ROC* 0.5). Kinerja ini menunjukkan bahwa model-model klasik yang diuji tidak cocok dan tidak mampu membedakan secara efektif antara Kelas 0, 1, dan 2.

Secara keseluruhan, nilai akurasi yang tercatat menunjukkan bahwa *Decision Tree* hanya mencapai 28.41% dalam kasus terburuk, yang berada di bawah akurasi acak sebesar 33.3% untuk tiga kelas. Hal ini menegaskan bahwa model sederhana ini tidak mampu mengenali pola yang terdapat dalam data, kemungkinan besar disebabkan oleh adanya tumpang tindih yang sangat besar di antara kelas-kelas dalam ruang fitur. Oleh karena itu, semua model yang diuji sama sekali tidak layak digunakan dalam sistem dunia nyata, dan ada kebutuhan mendesak untuk beralih ke teknik yang lebih canggih, seperti pemilihan fitur yang lebih mendalam atau penggunaan model ensemble yang lebih kuat dan jaringan saraf buatan.

REFERENSI

[1] F. Lestari Sarpangga Putri, "Decision-Making System for Determining the Location of Public Electric Charging Stations (SPLU) with Machine Learning: Sistem Pengambilan Keputusan Penentuan Lokasi Stasiun Pengisian Listrik Umum (SPLU) dengan Machine Learning," pp. 1–30, 2024.

[2] S. Suryani, M. F. Fayyad, D. T. Savra, V. Kurniawan, and B. H. Estanto, "Sentiment Analysis of Towards Electric Cars using Naive Bayes Classifier and Support Vector Machine Algorithm," Public Research Journal of Engineering, Data Technology and Computer Science, vol. 1, no. 1, pp. 1–9, 2023, doi: 10.57152/predatecs.v1i1.814.

[3] T. P. Balakrishnan, S. Sasikumar, and M. Premalatha, "A Comparative Analysis of Machine Learning Approaches for State-of-Charge Forecasting for Enhancing Lithium-ion Battery Management in Electric Vehicles," Nanotechnol Percept, vol. 20, no. S5, pp. 260–273, 2024, doi: 10.62441/nano-ntp.v20is5.21.

[4] M. P. Panggabean, "Studi Perbandingan Antara Algoritma Klasifikasi Machine Learning untuk Identifikasi Gangguan pada Jaringan Distribusi Listrik," Fakultas Teknik , Universitas Medan Area, Indonesia, no. Vol. 1 No. 1 (2023): Tugas Mahasiswa Elektro, pp. 1–13, 2024.

[5] F. Bellizio, B. Dijkstra, A. Fertig, J. Van Dijk, and P. Heer, "Machine learning approaches for the prediction of public EV charge point flexibility," Sustainable Energy, Grids and Networks, vol. 42, no. December 2024, p. 101657, 2025, doi: 10.1016/j.segan.2025.101657.

[6] I. W. D. Wiguna, D. V. Waas, I. K. A. G. Wiguna, and M. L. Radhitya, "Comparison of SVM & Naïve Bayes Methods in Sentiment Analysis of Electric Vehicle Subsidy Policy Based on X Data," Journal of Engineering and Scientific Research, vol. 6, no. 1, pp. 23–30, 2024, doi: 10.23960/jesr.v6i1.158.

[7] G. N. Hendrawan and H. Kusniyati, "Evaluasi Performa Naive Bayes dan SVM dalam Analisis Sentimen Kendaraan Listrik di Media Sosial Twitter Evaluating the Performance of Naive Bayes and SVM in Sentiment Analysis of Electric Vehicles on Twitter Social Media," Journal of Computing Engineering, System and Science) e-ISSN, vol. 9, no. 1, pp. 299–313, 2024, [Online]. Available: www.jurnal.unimed.ac.id

[8] G. H. Kusuma, I. Permana, F. N. Salisah, M. Afdal, M. Jazman, and A. Marsal, "Pendekatan Machine Learning: Analisis Sentimen Masyarakat Terhadap Kendaraan Listrik Pada Sosial Media X," JUSIFO (Jurnal Sistem Informasi), vol. 9, no. 2, pp. 65–76, 2023, doi: 10.19109/jusifo.v9i2.21354.

[9] J. Homepage, W. Ningsih, B. Alfianda, and D. Wulandari, "MALCOM:

Indonesian Journal of Machine Learning and Computer Science Comparison of Naive Bayes and SVM Algorithms in Twitter Sentiment Analysis on Electric Car Use in Indonesia Perbandingan Algoritma SVM dan Naïve Bayes dalam Analisis Sentimen Twitter pada," vol. 4, no. 2, pp. 556–562, 2024.

[10] T. Prasetyo, A. A. Waskita, and T. Taryo, "Analisis Sentimen Pengguna Seputar Kendaraan Listrik di Twitter dengan Penerapan Algoritma Naïve Bayes, KNN, dan Decision Tree untuk Klasifikasi," Jurnal SISKOM-KB (Sistem Komputer dan Kecerdasan Buatan), vol. VIII, no. 2, pp. 108–117, 2025.

[11] A. L. M. R. Amin, "Analysis Opini Publik Terhadap Kendaraan Listrik Menggunakan Algoritma Naïve Bayes Classifier (Nbc) Dengan Ekstraksi Fitur Tf …," 2023, [Online]. Available: http://eprints.unram.ac.id/id/eprint/43485

[12] Y. Mohammed, A. Manoharan, S. Kappagantula, and H. Manoharan, "Optimizing Electric Vehicle Charging Costs Using Machine Learning," Ingenierie des Systemes d'Information, vol. 29, no. 3, pp. 1085–1095, 2024, doi: 10.18280/isi.290326.

[13] E. Pranadjaya, E. S. Pangestu, C. O. Sereati, S. Octaviani, and 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: 10.25170/jurnalelektro.v17i1.5429.

[14] M. Fajri, "Analisis peramalan konsumsi energi listrik dengan metode extreme learning machine beserta tingkat akurasinya di kota pekanbaru tugas akhir," 2021.

[15] G L Pritalia, "Analisis Komparatif Algoritme Machine Learning pada Klasifikasi Kualitas Air Layak Minum," Konvergensi Teknologi dan Sistem Informasi (KONSTELASI), vol. 2, no. 1, pp. 43–55, 2022, [Online]. Available: https://ojs.uajy.ac.id/index.php/konstelasi/article/download/5630/2535.