



# Klasifikasi Metode Pembayaran Transaksi Menggunakan Algoritma *Naïve Bayes* dan *Support Vector Machine* (Studi Kasus 17 Coffee & Eatery)

Lia Nur Aufa<sup>1\*</sup>, Nurhadi<sup>2</sup>, Yulia Arvita<sup>3</sup>

<sup>1,2,3</sup> Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dinamika Bangsa, Indonesia

\*Penulis Korespondensi: [lianuraufa@student.unama.ac.id](mailto:lianuraufa@student.unama.ac.id)

**Abstract.** This study aims to classify customer payment methods at 17 Coffee & Eatery using machine learning algorithms, namely *Naïve Bayes* and *Support Vector Machine (SVM)*. The increasing use of digital and non-cash payments has generated large volumes of transaction data that are rarely analyzed optimally, even though such data contain valuable information for business decision making. This research used secondary transaction data collected from January to March 2025, consisting of 10,147 transaction records. The dataset included several attributes such as order time, payment time, transaction type, total sales, number of items, and payment method. Data preprocessing was performed through data cleaning, feature engineering, normalization, and label encoding before being divided into training and testing sets with an 80:20 ratio. The *Naïve Bayes* and *SVM* models were then trained and evaluated using accuracy, precision, recall, *F1-score*, and *ROC-AUC* metrics. The results show that both algorithms were able to classify payment methods effectively, but *SVM* achieved higher accuracy and more stable performance than *Naïve Bayes*. These findings indicate that *SVM* is more suitable for handling complex and heterogeneous transaction patterns. The implementation of machine learning for transaction classification can support more efficient financial management and data-driven decision making for small and medium enterprises in the culinary sector.

**Keywords:** classification; machine learning; *Naïve Bayes*; payment method; support vector machine

**Abstrak.** Penelitian ini bertujuan untuk mengklasifikasikan metode pembayaran pelanggan di 17 Coffee & Eatery menggunakan algoritma *machine learning*, yaitu *Naïve Bayes* dan *Support Vector Machine (SVM)*. Peningkatan penggunaan pembayaran non-tunai dan digital menghasilkan data transaksi yang besar, namun sering kali belum dimanfaatkan secara optimal untuk mendukung pengambilan keputusan bisnis. Data yang digunakan dalam penelitian ini merupakan data sekunder transaksi pada periode Januari hingga Maret 2025 dengan total 10.147 transaksi. Dataset mencakup atribut waktu pemesanan, waktu pembayaran, jenis transaksi, jumlah item, total penjualan, serta metode pembayaran. Data diproses melalui tahapan pembersihan, rekayasa fitur, normalisasi, dan pengkodean label, kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20. Model *Naïve Bayes* dan *SVM* selanjutnya dilatih dan dievaluasi menggunakan metrik akurasi, *precision*, *recall*, *F1-score*, dan *ROC-AUC*. Hasil penelitian menunjukkan bahwa kedua algoritma mampu melakukan klasifikasi dengan baik, namun *SVM* menghasilkan tingkat akurasi dan kestabilan kinerja yang lebih tinggi dibandingkan *Naïve Bayes*. Temuan ini menunjukkan bahwa *SVM* lebih efektif dalam menangani pola transaksi yang kompleks. Penerapan model klasifikasi ini diharapkan dapat membantu pengelolaan transaksi keuangan secara lebih efisien serta mendukung pengambilan keputusan berbasis data pada UMKM di sektor kuliner.

**Kata kunci:** klasifikasi; machine learning; metode pembayaran; *Naïve Bayes*; support vector machine

## 1. LATAR BELAKANG

Perkembangan industri kuliner di Indonesia mengalami pertumbuhan yang pesat seiring meningkatnya penggunaan sistem pembayaran digital seperti QRIS dan transfer bank. Perubahan ini menyebabkan volume dan kompleksitas data transaksi keuangan UMKM semakin meningkat, sehingga pengelolaan data secara manual menjadi tidak lagi efisien dan berpotensi menimbulkan kesalahan pencatatan (Faridawati et al., 2024). Transaksi keuangan tidak hanya mencerminkan aktivitas penjualan, tetapi juga memuat informasi penting terkait

perilaku konsumen, metode pembayaran, serta kinerja operasional usaha (Alkamat et al., 2024).

Pemanfaatan data transaksi sebagai dasar pengambilan keputusan bisnis masih relatif rendah pada UMKM. Banyak pelaku usaha hanya menggunakan data transaksi sebagai catatan administrasi tanpa analisis lebih lanjut, padahal data tersebut mengandung pola yang dapat digunakan untuk meningkatkan efisiensi, memprediksi preferensi pelanggan, serta memperbaiki strategi operasional (Rachman et al., 2021). Keterbatasan literasi digital dan ketiadaan sistem analitik menjadi kendala utama dalam optimalisasi data tersebut.

*Machine learning* telah terbukti efektif dalam mengolah dan mengklasifikasikan data transaksi keuangan. Algoritma klasifikasi seperti *Naïve Bayes* dan *Support Vector Machine* (SVM) mampu mempelajari pola dari data historis dan memprediksi kelas data baru dengan tingkat akurasi yang tinggi (Hermanto et al., 2020). (Ossani et al., 2021) menunjukkan bahwa teknik *machine learning* memberikan performa yang sangat baik dalam mengklasifikasikan data berbasis karakteristik produk dan transaksi, sedangkan (Afriyie et al., 2023) membuktikan efektivitas metode *supervised learning* dalam mendeteksi dan mengelompokkan transaksi perbankan secara akurat.

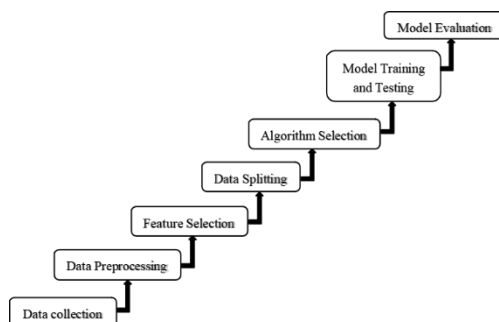
Meskipun demikian, penerapan *machine learning* untuk klasifikasi metode pembayaran pada UMKM kuliner masih terbatas, khususnya menggunakan data transaksi riil dalam skala besar. Oleh karena itu, penelitian ini memfokuskan pada penerapan dan perbandingan algoritma *Naïve Bayes* dan *Support Vector Machine* untuk mengklasifikasikan metode pembayaran transaksi di 17 Coffee & Eatery. Hasil penelitian ini diharapkan dapat memberikan dasar pengambilan keputusan berbasis data serta meningkatkan efisiensi pengelolaan keuangan usaha.

## 2. KAJIAN TEORITIS

### ***Machine Learning* dalam Klasifikasi Data**

*Machine learning* merupakan cabang kecerdasan buatan yang memungkinkan sistem komputer belajar dari data dan membuat prediksi tanpa diprogram secara eksplisit (Roihan et al., 2020). Pendekatan ini banyak diterapkan dalam berbagai bidang, termasuk analisis sentimen untuk mengklasifikasikan ulasan pengguna ke dalam kategori positif, negatif, dan netral guna memahami opini serta meningkatkan kualitas layanan aplikasi (Maulana et al., 2024). Berdasarkan metode pembelajarannya, *machine learning* dibedakan menjadi *supervised learning* dan *unsupervised learning* yang umum digunakan untuk tugas klasifikasi dan pengelompokan data (Purmala, 2021). Selain itu, terdapat *semi-supervised learning* dan

*reinforcement learning* yang diterapkan ketika data berlabel terbatas atau pembelajaran melibatkan interaksi langsung dengan lingkungan (Ananto et al., 2023).



**Gambar 1.** Tahapan *Machine Learning* (Arindi et al., 2022).

Secara umum, proses machine learning meliputi pengumpulan data, pra-pemrosesan, pemilihan fitur, pembagian data, pelatihan model, serta evaluasi kinerja menggunakan metrik seperti akurasi, presisi, recall, dan f1-score (Nawawi et al., 2024).

### **Data Preprocessing**

*Data Preprocessing* merupakan proses mengubah dan memperbaiki data mentah agar lebih mudah dipahami serta dapat diproses oleh algoritma *Machine Learning*, mengingat data mentah sering kali tidak lengkap, tidak konsisten, dan memiliki format yang tidak sesuai (Tuntun et al., 2022). Proses ini harus disesuaikan dengan tujuan penelitian karena berperan penting dalam meningkatkan akurasi dan kinerja model algoritma klasifikasi (Ryzhkov et al., 2023).

### **Klasifikasi**

Klasifikasi adalah suatu proses atau tugas dalam *Machine Learning* yang bertujuan untuk memisahkan satu kelas data dengan kelas lainnya, dengan menentukan ciri-ciri jenis tertentu melalui pemeriksaan perilaku dan ciri-ciri kelompok yang ditentukan (Romli & Zy, 2020).

### **Algoritma Naïve Bayes**

*Naïve Bayes* merupakan pengklasifikasi Bayesian yang mengasumsikan setiap atribut saling bebas secara bersyarat terhadap kelas tertentu untuk menyederhanakan proses perhitungan (Rozaq, 2019). Algoritma ini memiliki keunggulan karena membutuhkan sedikit data pelatihan, dapat digunakan pada data kuantitatif maupun kualitatif, serta mampu menangani nilai hilang, namun memiliki keterbatasan ketika probabilitas bersyarat bernilai nol yang menyebabkan hasil prediksi menjadi nol (Trisna, 2023).

## Support Vector Machine (SVM)

Support Vector Machine merupakan algoritma *machine learning* yang digunakan untuk klasifikasi dan regresi dengan cara mencari *hyperplane* optimal yang memaksimalkan jarak antar kelas sehingga kesalahan klasifikasi dapat diminimalkan (Sasongko, 2016). SVM efektif digunakan pada data berdimensi tinggi dan mampu menangani hubungan non-linear melalui fungsi kernel, serta menerapkan prinsip *Structural Risk Minimization* (SRM) untuk mencegah *overfitting* dan meningkatkan kemampuan generalisasi model (Kurniawan et al., 2022). Proses penentuan *hyperplane* terbaik didasarkan pada titik data terdekat yang disebut *support vector*, yang berperan penting dalam membedakan dua kelas atau lebih secara linear maupun non-linear (Wahyuni & Kusumodestoni, 2024).

## 3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen komparatif untuk membandingkan kinerja algoritma *Naïve Bayes* dan *Support Vector Machine* (SVM) dalam mengklasifikasikan metode pembayaran transaksi pelanggan di 17 Coffee & Eatery. Data yang digunakan merupakan data sekunder yang diperoleh dari sistem kasir (Point of Sale) periode Januari–Maret 2025 dengan total 10.147 transaksi. Variabel target dalam penelitian ini adalah metode pembayaran yang terdiri atas tiga kelas, yaitu Cash, QRIS, dan Transfer, sedangkan variabel prediktor meliputi atribut transaksi seperti waktu order, waktu bayar, jenis order, produk, nama kasir, jumlah item, total penjualan, dan durasi transaksi.

Data terlebih dahulu melalui tahap pra-pemrosesan yang meliputi pembersihan data, standarisasi nilai numerik, pengkodean data kategorikal, ekstraksi fitur waktu, serta normalisasi menggunakan *MinMaxScaler*. Dataset kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan teknik stratifikasi. Model *Naïve Bayes* dan SVM dilatih menggunakan data latih dan dievaluasi pada data uji dengan metrik *accuracy*, *precision*, *recall*, dan F1-score untuk menentukan algoritma yang paling efektif dalam memprediksi metode pembayaran pelanggan.

## 4. HASIL DAN PEMBAHASAN

### Deskripsi Dataset

Dataset penelitian ini diperoleh dari sistem *Point of Sale* (POS) 17 Coffee & Eatery yang mencatat seluruh transaksi pelanggan selama periode Januari–Maret 2025. Data awal berjumlah 10.147 transaksi yang merepresentasikan aktivitas pembayaran pelanggan dalam

kondisi operasional normal tanpa pengaruh promosi besar. Data ini mencakup atribut waktu, produk, jenis order, nilai transaksi, serta metode pembayaran. Distribusi awal metode pembayaran ditunjukkan pada Tabel 4.1. Terlihat bahwa metode *Cash* merupakan metode yang paling dominan, sedangkan QRIS memiliki proporsi yang jauh lebih kecil. Ketidakseimbangan distribusi kelas ini menjadi karakteristik penting yang berpengaruh terhadap proses pembelajaran model klasifikasi.

**Tabel 1.** Distribusi Metode Pembayaran Awal

Metode Pembayaran	Jumlah
Cash	6.516
Transfer	3.340
QRIS	283
Kombinasi metode	2
Total	10.141

Berdasarkan Tabel.1, terlihat bahwa metode pembayaran *Cash* mendominasi transaksi dengan proporsi lebih dari 64% dari total data, sedangkan QRIS hanya mencakup sekitar 2,8%. Ketimpangan ini menunjukkan bahwa sebagian besar pelanggan masih lebih memilih pembayaran tunai dibandingkan non-tunai. Kondisi ini berpotensi menyebabkan bias pada model klasifikasi karena algoritma cenderung lebih mudah mempelajari pola dari kelas mayoritas.

**Tabel 2.** Atribut Dataset

No	Atribut	Deskripsi
1	No Transaksi	Kode unik transaksi
2	Waktu Order	Waktu pemesanan
3	Waktu Bayar	Waktu pembayaran
4	Outlet	Lokasi transaksi
5	Produk	Menu yang dipesan
6	Jenis Order	Jenis pemesanan
7	Total Penjualan	Nilai transaksi
8	Sisa Tagihan	Sisa pembayaran
9	Metode Pembayaran	Cash, QRIS, Transfer
10	Bayar	Informasi pembayaran
11	Order	Informasi pesanan

Tabel.2 menunjukkan bahwa dataset memiliki kombinasi atribut numerik dan kategorikal yang kaya. Atribut waktu, nilai transaksi, dan jenis order memungkinkan model menangkap pola perilaku pelanggan, sedangkan metode pembayaran berfungsi sebagai variabel target yang akan diprediksi.

### Pra-pemrosesan Data

**Tabel 3.** Missing Value

Kolom	Jumlah
Waktu Bayar	6
Metode Pembayaran	6
Bayar	6

Dari Tabel.3 dapat dilihat bahwa terdapat enam transaksi yang tidak memiliki informasi pembayaran lengkap. Data ini dihapus karena keberadaannya dapat mengganggu proses pelatihan model dan menurunkan akurasi prediksi.

**Tabel 4.** Distribusi Kelas Setelah Pelabelan

Kelas	Jumlah
Cash	6.516
Non-Cash	3.623
Total	10.139

Penggabungan QRIS dan *Transfer* menjadi kelas *Non-Cash* menghasilkan dua kelas utama yang lebih seimbang dibandingkan sebelumnya. Meskipun *Cash* masih dominan, proporsi *Non-Cash* yang mencapai 35,7% memberikan variasi yang cukup bagi model untuk mempelajari pola pembayaran digital.

**Tabel 5.** Pembagian Dataset

Dataset	Jumlah
Training	8.111
Testing	2.028

Pembagian data dengan rasio 80:20 memastikan bahwa sebagian besar data digunakan untuk melatih model, sementara data uji digunakan untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

## Hasil

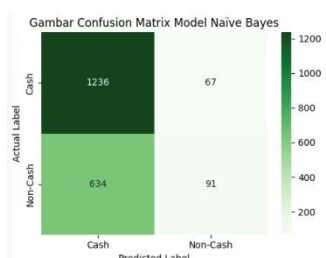
### *Naive Bayes*

**Tabel 6.** Perbandingan *Naive Bayes*

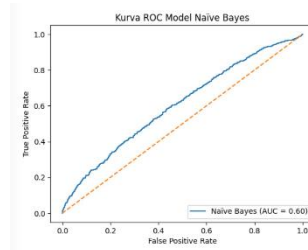
Model	Akurasi
MultinomialNB	0.65
ComplementNB	0.64

Tabel.6 menunjukkan bahwa MultinomialNB memiliki kinerja sedikit lebih baik dibandingkan ComplementNB. Hal ini mengindikasikan bahwa distribusi fitur pada data transaksi lebih sesuai dengan asumsi probabilistik MultinomialNB.

**Gambar 2.** Confusion Matrix *Naive Bayes*



Confusion matrix *Naive Bayes* menunjukkan bahwa model sangat baik dalam memprediksi transaksi *Cash*, namun masih sering salah mengklasifikasikan transaksi *Non-Cash* sebagai *Cash*. Hal ini menegaskan bahwa *Naive Bayes* cenderung bias terhadap kelas mayoritas.

**Gambar 3.** Kurva ROC Naïve Bayes

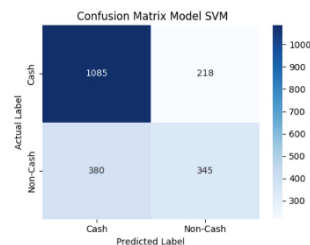
Kurva ROC yang relatif mendekati garis diagonal menunjukkan bahwa kemampuan pemisahan kelas oleh Naïve Bayes masih terbatas, yang tercermin dari nilai AUC sebesar 0,60.

### **Support Vector Machine (SVM)**

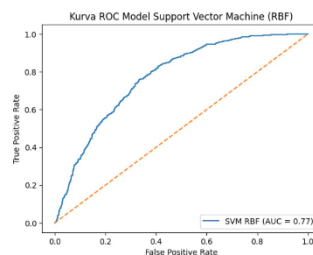
**Tabel 7.** Parameter Terbaik SVM

Parameter	Nilai
Kernel	RBF
C	3
Gamma	0.03
CV Accuracy	0.7242

Parameter pada Tabel 4.7 menunjukkan bahwa kernel RBF dengan nilai C dan gamma tertentu memberikan keseimbangan terbaik antara kompleksitas model dan kemampuan generalisasi.

**Gambar 4.** Confusion Matrix SVM

Confusion matrix SVM memperlihatkan bahwa model ini mampu mengklasifikasikan baik *Cash* maupun *Non-Cash* secara lebih seimbang dibandingkan *Naïve Bayes*, dengan jumlah kesalahan klasifikasi yang lebih rendah pada kelas *Non-Cash*.

**Gambar 5.** Kurva ROC SVM

Kurva ROC SVM yang lebih menjauhi garis diagonal menunjukkan kemampuan pemisahan kelas yang lebih baik, yang ditunjukkan oleh nilai AUC sebesar 0,75.

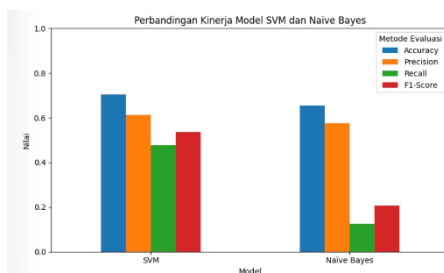
**Perbandingan Model**

**Tabel 8.** Perbandingan Kinerja

Model	Akurasi	Precision	Recall	F1-Score	AUC
Naive Bayes	0.65	0.66	0.95	0.78	0.60
SVM	0.71	0.76	0.83	0.79	0.75

Tabel.8 menunjukkan bahwa SVM unggul pada hampir seluruh metrik evaluasi, khususnya pada akurasi dan AUC. Meskipun *Naive Bayes* memiliki *recall* tinggi, hal ini disebabkan oleh kecenderungan memprediksi kelas mayoritas (*Cash*), sehingga kurang mampu mendeteksi transaksi *Non-Cash* secara akurat.

**Gambar 6.** Grafik Perbandingan Model



Grafik memperlihatkan bahwa SVM memiliki performa yang lebih seimbang, sedangkan *Naive Bayes* menunjukkan ketimpangan antara *recall* dan *precision*.

**Pembahasan**

Hasil penelitian menunjukkan bahwa *Support Vector Machine* (SVM) memiliki kinerja yang lebih unggul dibandingkan *Naive Bayes* dalam mengklasifikasikan metode pembayaran transaksi di 17 Coffee & Eatery. Keunggulan ini terlihat dari nilai akurasi, *F1-score*, dan AUC yang lebih tinggi pada model SVM. Temuan ini sejalan dengan teori margin maksimum pada SVM yang memungkinkan pemisahan kelas yang lebih optimal pada data yang kompleks dan tidak linier (Vapnik, 1998). Dengan penggunaan kernel RBF, SVM mampu menangkap hubungan nonlinier antara fitur transaksi seperti nilai penjualan, waktu transaksi, dan jenis order, sehingga meningkatkan kemampuan model dalam membedakan transaksi *Cash* dan *Non-Cash*.

Sebaliknya, *Naive Bayes* menunjukkan keterbatasan dalam mengklasifikasikan transaksi *Non-Cash* meskipun memiliki nilai *recall* yang tinggi pada kelas *Cash*. Hal ini disebabkan oleh asumsi independensi antar fitur yang jarang terpenuhi pada data transaksi nyata, di mana banyak atribut seperti total penjualan dan durasi transaksi saling berkorelasi (Mitchell, 1997). Selain itu, ketidakseimbangan distribusi kelas juga memengaruhi performa model, karena algoritma probabilistik seperti *Naive Bayes* cenderung memihak kelas mayoritas ketika data tidak seimbang (He & Garcia, 2009).

Temuan penelitian ini memperkuat hasil penelitian sebelumnya yang menunjukkan bahwa SVM lebih efektif dibandingkan *Naïve Bayes* dalam klasifikasi data keuangan dan transaksi digital. Model SVM mampu memberikan performa yang lebih stabil dan seimbang dalam mendeteksi berbagai kelas pembayaran, sehingga lebih sesuai diterapkan pada sistem analisis transaksi UMKM (Afriyie et al., 2023). Dengan demikian, penerapan SVM pada *17 Coffee & Eatery* berpotensi meningkatkan kualitas pengelolaan data transaksi dan mendukung pengambilan keputusan berbasis data.

## 5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa algoritma *Support Vector Machine* (SVM) memiliki kinerja yang lebih baik dibandingkan *Naïve Bayes* dalam mengklasifikasikan metode pembayaran transaksi di *17 Coffee & Eatery*. Hal ini ditunjukkan oleh nilai akurasi, *F1-score*, dan AUC yang lebih tinggi, serta kemampuan SVM dalam mengklasifikasikan transaksi *Cash* dan *Non-Cash* secara lebih seimbang. Sementara itu, *Naïve Bayes* cenderung bias terhadap kelas mayoritas, sehingga kurang optimal dalam mendeteksi transaksi *Non-Cash*. Temuan ini menunjukkan bahwa penggunaan algoritma berbasis margin seperti SVM lebih sesuai untuk data transaksi keuangan UMKM yang bersifat kompleks dan tidak seimbang.

Sebagai saran, penelitian selanjutnya dapat menambahkan fitur yang lebih kaya, seperti kategori produk, profil pelanggan, atau waktu kunjungan, untuk meningkatkan kemampuan model dalam menangkap pola perilaku pembayaran. Selain itu, penerapan teknik penanganan data tidak seimbang seperti SMOTE atau class weighting disarankan agar kinerja klasifikasi, khususnya untuk kelas *Non-Cash*, dapat lebih ditingkatkan. Pengembangan sistem klasifikasi berbasis machine learning ini juga berpotensi diintegrasikan langsung dengan sistem kasir untuk mendukung analisis dan pengambilan keputusan secara *real time*.

## UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada pihak *17 Coffee & Eatery* yang telah memberikan akses dan izin penggunaan data transaksi sebagai objek penelitian ini. Penulis juga mengucapkan terima kasih kepada dosen pembimbing dan pihak Program Studi yang telah memberikan arahan, masukan, serta dukungan selama proses penelitian dan penyusunan artikel ini. Selain itu, apresiasi diberikan kepada semua pihak yang turut membantu, baik secara langsung maupun tidak langsung, sehingga penelitian ini dapat diselesaikan dengan baik.

## DAFTAR REFERENSI

- Afriyie, J. K., Tawiah, K., Pels, W. A., Addai-Henne, S., Dwamena, H. A., Owiredo, E. O., Ayeh, S. A., & Eshun, J. (2023). A supervised machine learning algorithm for detecting and predicting fraud in credit card transactions. *Decision Analytics Journal*, 6, 100163.
- Alkamalat, A., Alvianti, S. N., Qomariyah, J., Maulana, B. Y., & Adiyanto, M. R. (2024). Penerapan Pencatatan Keuangan Sederhana Pada UMKM Elf's Cake. *Jurnal Media Akademik (JMA)*, 2(7).
- Ananto, D. T., Mahardewantoro, D. D., Mustafa, F., Ardianto, M. G., Rafi, M. M., Zein, R. A., Saputra, O. E., Mujiastuti, R., Rosanti, N., & Adharani, Y. (2023). Edukasi dan pelatihan pengenalan machine learning dan computer vision untuk mengeksplorasi potensi visual. *Prosiding Seminar Nasional Pengabdian Masyarakat LPPM UMJ*.
- Arindi, P., Lumbanbatu, K., & Novriyenni, N. (2022). Klasifikasi Kecanduan Rokok Dengan Naive Bayes. *Pelita Informatika: Informasi Dan Informatika*, 11(1).
- Faridawati, S. A., Herdi, H., & Lamawitak, P. L. (2024). Analisis Penerapan Sistem Informasi Akuntansi untuk Meningkatkan Efisiensi dan Keamanan Keuangan UMKM (Cafe Rindu Lokaria). *Jurnal Ekonomi, Akuntansi, Dan Perpajakan*, 1(4), 189–215.
- Hermanto, H., Mustopa, A., & Kuntoro, A. Y. (2020). Algoritma Klasifikasi Naive Bayes Dan Support Vector Machine Dalam Layanan Komplain Mahasiswa. *JITK (Jurnal Ilmu Pengetahuan Dan Teknologi Komputer)*, 5(2), 211–220.
- Kurniawan, A. A., Mustikasari, M., & Korespondensi, P. (2022). Evaluasi Kinerja MLLIB APACHE SPARK pada Klasifikasi Berita Palsu dalam Bahasa Indonesia. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIIK)*, 9(3).
- Maulana, B. A., Fahmi, M. J., Imran, A. M., & Hidayati, N. (2024). Analisis Sentimen Terhadap Aplikasi Pluang Menggunakan Algoritma Naive Bayes dan Support Vector Machine (SVM): Sentiment Analysis of Pluang Applications With Naive Bayes and Support Vector Machine (SVM) Algorithm. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(2), 375–384.
- Nawawi, H. M., Hikmah, A. B., Mustopa, A., & Wijaya, G. (2024). Model Klasifikasi Machine Learning untuk Prediksi Ketepatan Penempatan Karir. *Jurnal Saintekom: Sains, Teknologi, Komputer Dan Manajemen*, 14(1), 13–25.
- Ossani, P. C., Rossoni, D. F., Cirillo, M. Â., & Borém, F. M. (2021). Classification of specialty coffees using machine learning techniques. *Research, Society and Development*, 10(5), e13110514732–e13110514732.
- Purmala, Y. A. (2021). Implementation of Machine Learning to Increase Productivity in the Manufacturing Industry: A Literature Review. *Jurnal Operations Excellence: Journal of Applied Industrial Engineering*, 13(2), 267–275.
- Rachman, R., Handayani, R. N., & Artikel, I. (2021). Klasifikasi algoritma Naive Bayes dalam memprediksi tingkat kelancaran pembayaran sewa teras UMKM. *J. Inform*, 8(2), 111–122.
- Roihan, A., Sunarya, P. A., & Rafika, A. S. (2020). Pemanfaatan machine learning dalam berbagai bidang. *Jurnal Khatulistiwa Informatika*, 5(1), 490845.
- Romli, I., & Zy, A. T. (2020). Penentuan jadwal overtime dengan klasifikasi data karyawan menggunakan algoritma C4. 5. *J-SAKTI (Jurnal Sains Komputer Dan Informatika)*, 4(2), 694–702.

- Rozaq, A. (2019). Klasifikasi Penentuan Pinjaman Nasabah di Bank XYZ Menggunakan Naïve Bayes. *Prosiding Seminar Nasional Teknologi Informasi Dan Komunikasi (SENATIK)*, 2(1), 7–10.
- Ryzhkov, F. V, Ryzhkova, Y. E., & Elinson, M. N. (2023). Python in chemistry: physicochemical tools. *Processes*, 11(10), 2897.
- Sasongko, T. B. (2016). Komparasi dan Analisis Kinerja Model Algoritma SVM dan PSO-SVM (Studi Kasus Klasifikasi Jalur Minat SMA). *Jurnal Teknik Informatika Dan Sistem Informasi*, 2(2).
- Trisna, K. W. (2023). Model Penerimaan Pinjaman Nasabah Menggunakan Algoritma Naïve Bayes Dalam Dataset Bank. *JBASE-Journal of Business and Audit Information Systems*, 6(1).
- Tuntun, R., Kusrini, K., & Kusnawi, K. (2022). Analisis Perbandingan Kinerja Algoritma Klasifikasi dengan Menggunakan Metode K-Fold Cross Validation. *Jurnal Media Informatika Budidarma*, 6(4), 2111.
- Wahyuni, S. D., & Kusumodestoni, R. H. (2024). Optimalisasi Algoritma Support Vector Machine (SVM) Dalam Klasifikasi Kejadian Data Stunting. *Bulletin of Information Technology (BIT)*, 5(2), 56–64.