

BAB II

LANDASAN TEORI

2.1. Teori-Teori dan Konsep Dasar

Pembelajaran mesin (*machine learning*) merupakan bagian dari kecerdasan buatan (*artificial intelligence*) yang berfokus pada pengembangan algoritma yang mampu mengenali pola dan membuat prediksi berdasarkan data historis. Dalam konteks bisnis ritel seperti Toko Sembako Mentari, pembelajaran mesin digunakan untuk menganalisis data transaksi harian, menemukan pola pembelian pelanggan, serta mendukung pengambilan keputusan yang berkaitan dengan stok dan promosi secara otomatis. Di antara berbagai teknik yang digunakan dalam *machine learning*, klasifikasi menjadi salah satu yang paling relevan karena fungsinya dalam mengelompokkan produk ke dalam kategori-kategori yang telah ditentukan, seperti kategori produk atau kelompok harga (Božić et al., 2023).

2.1.1. Pengertian Pembelajaran Mesin dan Klasifikasi

Pembelajaran mesin mengacu pada penggunaan algoritma untuk membangun model dari data yang dapat memprediksi atau mengklasifikasikan data baru. Secara umum, terdapat dua jenis utama dalam pembelajaran mesin: *supervised learning* dan *unsupervised learning*. Dalam *supervised learning*, model dilatih menggunakan data yang sudah dilabeli, di mana input diberikan bersama dengan output yang benar. Sebagai contoh, di Toko Sembako Mentari, produk diklasifikasikan berdasarkan fitur transaksi harian seperti harga, frekuensi pembelian, waktu transaksi, dan jenis produk untuk menentukan tingkat minat

pelanggan terhadap barang tersebut. Sebaliknya, *unsupervised learning* digunakan ketika data tidak memiliki label, dengan tujuan menemukan pola tersembunyi seperti pengelompokan pelanggan berdasarkan kebiasaan pembelian tanpa menentukan kategori minat produk secara langsung. Metode ini sering digunakan untuk segmentasi pasar atau analisis perilaku pelanggan tanpa membutuhkan label yang jelas (Sarker, 2021).

Di antara berbagai metode pembelajaran mesin, klasifikasi adalah salah satu tugas utama. Klasifikasi adalah proses mengategorikan data ke dalam kategori-kategori tertentu berdasarkan atribut atau fitur yang dimiliki oleh data tersebut. Sebagai contoh, dalam konteks Toko Sembako Mentari, klasifikasi dapat digunakan untuk memprediksi jenis produk yang paling diminati oleh pelanggan berdasarkan data transaksi sebelumnya. Model klasifikasi ini biasanya berfungsi untuk memetakan input data (seperti deskripsi produk atau harga) ke dalam salah satu kategori atau label yang sudah ditentukan, misalnya kategori produk atau jenis barang tertentu (Ding, 2023) (Lu, 2024).

2.1.2. Proses Klasifikasi dalam Pembelajaran Mesin

Proses klasifikasi dalam pembelajaran mesin terdiri dari beberapa tahapan penting yang melibatkan pengumpulan data, pemilihan fitur, pelatihan model, dan evaluasi kinerja model. Tahap pertama adalah pengumpulan data, di mana data yang relevan, seperti informasi produk dan transaksi, dikumpulkan dari berbagai sumber. Setelah data terkumpul, langkah berikutnya adalah persiapan data yang mencakup pembersihan data, penghapusan duplikasi, dan pengisian data yang hilang. Pada tahap ini, fitur transaksi harian seperti harga, jumlah pembelian, frekuensi transaksi,

dan kategori produk dipilih untuk membangun model klasifikasi produk paling diminati.

Setelah fitur dipilih, langkah berikutnya adalah pelatihan model, yang melibatkan penggunaan algoritma pembelajaran mesin untuk belajar dari data yang telah dipersiapkan. Dalam pendekatan *supervised learning*, model dilatih menggunakan data berlabel dari transaksi harian untuk mempelajari hubungan antara fitur produk (input) dan label tingkat minat pelanggan (output). Pada tahap ini, algoritma seperti *Support Vector Machines* (SVM) atau *Random Forest* dapat digunakan untuk membangun model klasifikasi yang dapat memprediksi kategori produk berdasarkan data transaksi yang diberikan.

Setelah model selesai dilatih, evaluasi model menjadi langkah berikutnya yang penting. Evaluasi ini bertujuan untuk memastikan bahwa model yang dibangun dapat memprediksi data baru dengan akurasi yang baik. Berbagai metrik evaluasi seperti akurasi, presisi, dan F1-score digunakan untuk menilai kinerja model klasifikasi. *Cross-validation* juga sering diterapkan untuk menghindari masalah *overfitting*, di mana model terlalu cocok dengan data pelatihan dan gagal menggeneralisasi pada data yang tidak terlihat sebelumnya (Ding, 2023)(Sarker, 2021).

2.1.3. Klasifikasi untuk Bisnis Ritel Toko Sembako Mentari

Klasifikasi dalam *machine learning* sangat relevan bagi bisnis ritel karena memungkinkan toko mengidentifikasi produk paling diminati berdasarkan data transaksi harian, sehingga mendukung strategi penjualan berbasis data. Di Toko Sembako Mentari, misalnya, klasifikasi dapat digunakan untuk mengelompokkan

produk ke dalam kategori tertentu yang lebih mudah dikelola dan dipasarkan. Dengan menggunakan model klasifikasi berbasis algoritma SVM dan *Random Forest*, Toko Sembako Mentari dapat memprediksi produk paling diminati pelanggan dan merencanakan strategi stok serta promosi dengan lebih efisien. Klasifikasi juga dapat digunakan untuk menganalisis tren penjualan, memperkirakan permintaan produk tertentu, dan mengidentifikasi pola perilaku konsumen (English et al., 2021)(Lu, 2024).

Selain itu, klasifikasi otomatis dapat mengurangi beban kerja manual dalam proses pengelompokan produk dan pengelolaan katalog, yang sering kali memerlukan banyak waktu dan sumber daya. Misalnya, model pembelajaran mesin dapat secara otomatis mengklasifikasikan produk berdasarkan kategori harga atau kategori produk tanpa *intervensi* manusia yang memakan waktu. Ini memungkinkan bisnis ritel seperti Toko Sembako Mentari untuk menghemat waktu, mengurangi kesalahan manusia, dan meningkatkan efisiensi operasional secara keseluruhan.

2.1.4. Tantangan dalam Mengaplikasikan Klasifikasi di Ritel

Meskipun penerapan klasifikasi dalam pembelajaran mesin menawarkan banyak keuntungan, terdapat beberapa tantangan yang perlu diatasi. Salah satunya adalah masalah kualitas data, di mana data yang buruk atau tidak lengkap dapat mempengaruhi kinerja model. Misalnya, jika data transaksi tidak lengkap atau tidak akurat, model klasifikasi yang dibangun mungkin menghasilkan prediksi yang tidak akurat. Oleh karena itu, penting untuk memastikan bahwa data yang digunakan

untuk melatih model memiliki kualitas yang tinggi dan representatif terhadap masalah yang ingin diselesaikan.

Selain itu, masalah bias juga menjadi perhatian dalam pengembangan model klasifikasi. Jika data pelatihan mengandung bias yang berasal dari sampel yang tidak representatif, maka model klasifikasi yang dihasilkan dapat menghasilkan prediksi yang tidak adil atau bias terhadap kelompok tertentu, seperti pelanggan atau produk tertentu. Oleh karena itu, sangat penting untuk mempertimbangkan aspek keadilan dan mitigasi bias dalam membangun model pembelajaran mesin untuk bisnis ritel (Consuegra-Ayala et al., 2025).



Gambar 2. 1 Pengumpulan Data

Gambar di atas ini menggambarkan proses umum dalam klasifikasi pembelajaran mesin, mulai dari pengumpulan data, persiapan data, pelatihan model, hingga evaluasi dan penerapan model.

2.2. Support Vector Machine (SVM) dan Random Forest (RF)

Penelitian ini menggunakan dua algoritma utama, yaitu *Support Vector Machine* (SVM) dan *Random Forest* (RF), untuk membandingkan kinerja

klasifikasi produk paling diminati di Toko Sembako Mentari berdasarkan data transaksi harian. Kedua algoritma ini sangat populer dalam klasifikasi dan memiliki kelebihan serta kekurangan masing-masing. Pemilihan kedua algoritma ini didasarkan pada karakteristik data transaksi harian yang kompleks serta tujuan penelitian untuk membandingkan kinerja klasifikasi secara komprehensif, serta kecocokannya dengan tugas yang ada dalam konteks ritel (Guerra-Londono et al., 2025).

2.2.1. Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin berbasis *supervised learning* yang sering digunakan untuk klasifikasi data. Prinsip dasar SVM adalah mencari sebuah *hyperplane* yang memisahkan data ke dalam dua kelas, dengan tujuan untuk memaksimalkan margin antara kedua kelas tersebut. Margin adalah jarak terdekat antara titik data dari masing-masing kelas dan *hyperplane*, yang berfungsi untuk memastikan klasifikasi yang lebih baik dan mengurangi kemungkinan kesalahan klasifikasi (Guo et al., 2024). SVM bertujuan untuk meminimasi risiko struktural dan lebih menekankan pada *generalization*, bukan hanya meminimalkan kesalahan pada data pelatihan (Cheng et al., 2023).

Keunggulan utama SVM adalah kemampuannya untuk menangani data nonlinier dengan bantuan fungsi kernel seperti *Radial Basis Function* (RBF), yang relevan untuk memetakan variasi harga dan volume pembelian produk ritel. Untuk itu, SVM menggunakan kernel *functions* seperti *Radial Basis Function* (RBF), *polynomial*, atau kernel lainnya, yang memungkinkan data dipetakan ke dalam dimensi yang lebih tinggi, di mana pemisahan linier dapat dilakukan (Cheng et al.,

2023)(Lohani & Rana, 2024). Misalnya, dalam konteks Toko Sembako Mentari, data produk yang memiliki berbagai atribut bisa saja tidak memiliki batas pemisah yang jelas. Oleh karena itu, penggunaan kernel dalam SVM membantu untuk menemukan *hyperplane* yang efektif meski data tidak linier.

Keunggulan utama SVM terletak pada kemampuannya untuk menangani data dengan jumlah fitur yang tinggi dan jumlah data pelatihan yang terbatas. SVM juga sering kali memberikan hasil klasifikasi yang sangat akurat, meskipun ukuran data relatif kecil dan fitur data sangat tinggi, seperti dalam kasus teks atau gambar yang telah diproses menjadi representasi fitur (Cheng et al., 2023)(Muhathir et al., 2024). Namun, SVM juga memiliki beberapa keterbatasan, antara lain pada pemilihan kernel yang tepat dan potensi waktu pelatihan yang lama untuk dataset yang sangat besar, terutama ketika menggunakan kernel non-linear yang kompleks (Lohani & Rana, 2024).

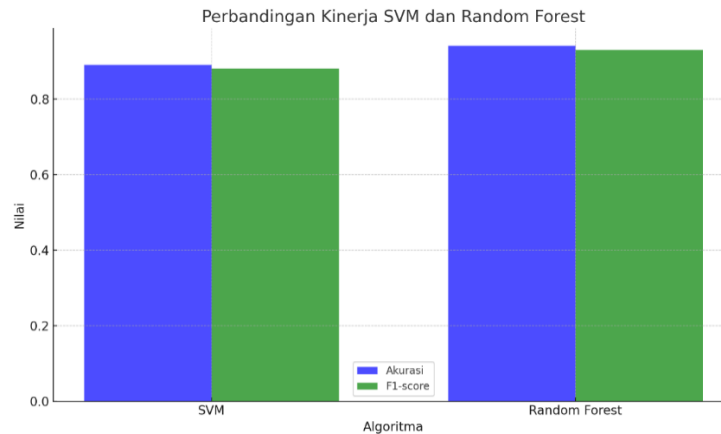
2.2.2. Random Forest (RF)

Random Forest (RF) adalah algoritma berbasis *ensemble learning* yang menggunakan banyak *decision trees* untuk melakukan klasifikasi. Setiap pohon keputusan dalam RF dibangun dengan menggunakan subset acak dari data pelatihan dan fitur yang tersedia, kemudian hasilnya digabungkan melalui *majority voting* (Zhou et al., 2025). Dengan menggunakan banyak pohon keputusan, RF mengurangi variansi dan *overfitting* yang sering terjadi pada model pohon keputusan tunggal. Keunggulan *Random Forest* adalah kemampuannya menilai *feature importance*, membantu pemilik toko mengidentifikasi faktor transaksi

harian seperti harga, frekuensi pembelian, dan kategori produk yang paling berpengaruh terhadap tingkat minat pelanggan.

Keunggulan utama RF adalah kemampuannya untuk menangani data yang sangat heterogen, yaitu data yang memiliki berbagai jenis fitur, baik numerik maupun kategorikal. Misalnya, dalam data transaksi ritel, variabel seperti harga produk (numerik) dan kategori produk (kategorikal) sering kali berinteraksi secara non-linear. RF dapat menangani interaksi ini secara efektif tanpa memerlukan rekayasa fitur yang kompleks (Farias et al., 2023)(Zhou et al., 2025). RF juga sangat efektif ketika data memiliki banyak interaksi kompleks antar fitur, yang sering ditemukan dalam dataset transaksi ritel.

RF juga lebih mudah diterapkan daripada SVM pada data yang lebih besar dan lebih heterogen, karena tidak memerlukan pemilihan kernel atau *tuning hiperparameter* sebanyak SVM. Hal ini membuat RF lebih praktis dan cepat untuk diterapkan pada masalah klasifikasi yang lebih besar dan kompleks, seperti yang sering terjadi pada data SKU atau transaksi penjualan yang mencakup berbagai produk dan atribut (Zhou et al., 2025). Namun, meskipun RF memiliki kinerja yang lebih stabil pada dataset besar, ia cenderung membutuhkan lebih banyak memori dan waktu untuk evaluasi jika jumlah pohon dalam hutan sangat besar (Farias et al., 2023).



Gambar 2. 2 Perbandingan Kinerja SVM dan RF

Grafik ini menunjukkan perbandingan kinerja antara SVM dan Random Forest dalam hal akurasi klasifikasi pada dataset dengan jumlah fitur yang tinggi dan kompleksitas tinggi. Hasil dari eksperimen ini dapat dilihat melalui akurasi klasifikasi yang dicapai oleh kedua algoritma.

2.3. Proses Machine Learning Untuk Klasifikasi Produk

Proses *machine learning* untuk klasifikasi produk paling diminati di Toko Sembako Mentari dilakukan secara sistematis, meliputi pengumpulan data transaksi harian, preprocessing data, pelatihan dan evaluasi model SVM dan RF, serta penerapan hasil klasifikasi dalam mendukung pengambilan keputusan bisnis. Setiap tahap tersebut memiliki peran yang sangat penting dalam memastikan bahwa model yang dibangun dapat memprediksi produk yang paling diminati dengan akurasi yang tinggi. Tahapan yang dilakukan tidak hanya terbatas pada pengumpulan data, tetapi juga mencakup pemilihan fitur yang relevan, pelatihan model dengan algoritma yang tepat, serta evaluasi menggunakan berbagai metrik untuk memastikan bahwa model yang diterapkan dapat berfungsi dengan baik di dunia nyata.

2.3.1. Pengumpulan dan Persiapan Data

Tahap pertama yang sangat krusial dalam setiap proyek machine learning adalah pengumpulan data. Pada tahap ini, data transaksi produk yang mencakup informasi seperti harga, jumlah pembelian, kategori produk, dan waktu transaksi dikumpulkan dari berbagai sumber. Data ini sering kali tidak dalam bentuk yang siap pakai dan membutuhkan pembersihan data yang melibatkan penghapusan duplikasi, pengisian nilai yang hilang, dan penanganan nilai yang tidak valid (Aparajit, Y., Sanap, S., & Kumar, 2023) (Alghamdi & Javaid, 2022). Selanjutnya, data yang telah dibersihkan perlu ditempatkan dalam format yang konsisten untuk digunakan dalam pelatihan model. Pada tahap ini juga, dilakukan normalisasi data untuk memastikan bahwa setiap fitur memiliki skala yang seragam, mencegah ketidakseimbangan yang bisa memengaruhi pelatihan model.

Proses data preprocessing ini sangat penting karena mengubah data mentah yang tidak terstruktur menjadi bentuk yang dapat dimanfaatkan oleh algoritma machine learning. Berbagai penelitian menunjukkan bahwa preprocessing data yang tepat dapat meningkatkan akurasi model secara signifikan dengan mengurangi informasi yang redundan dan mengatasi data yang hilang atau cacat (Li et al., 2023) (Mboweni et al., 2023). Oleh karena itu, langkah-langkah seperti imputasi nilai yang hilang dan normalisasi data menjadi hal yang sangat penting dalam memastikan kestabilan dan akurasi model yang dibangun.

2.3.2. Pemilihan Fitur (Feature Selection)

Pemilihan fitur (feature selection) adalah proses menentukan variabel input yang paling relevan agar model hanya mempelajari informasi yang benar-benar

berkontribusi terhadap hasil prediksi. Pada penelitian klasifikasi produk paling diminati di Toko Sembako Mentari, pemilihan fitur dilakukan dengan mempertimbangkan kesesuaian dengan rumusan masalah, ketersediaan data transaksi harian, serta hubungan langsung setiap variabel terhadap minat konsumen. Berdasarkan pertimbangan tersebut, fitur yang digunakan sebagai variabel prediktor adalah jumlah pembelian, frekuensi transaksi, dan harga satuan, sedangkan label diminati/tidak diminati berperan sebagai variabel target. Adapun nama produk hanya berfungsi sebagai identitas data dan tidak dijadikan fitur utama karena tidak secara langsung merepresentasikan pola permintaan. Pemilihan tiga fitur tersebut dinilai representatif karena mampu menggambarkan tingkat permintaan, intensitas pembelian, dan aspek harga yang memengaruhi keputusan konsumen. Dengan memilih fitur yang relevan, model dapat dibangun secara lebih sederhana, fokus, dan sesuai dengan karakteristik data UMKM yang relatif terbatas.

Pada penelitian ini, pemilihan fitur tidak diarahkan pada penambahan banyak atribut atau pada reduksi dimensi yang kompleks seperti Principal Component Analysis (PCA), karena dataset yang digunakan berskala kecil dan variabel utama telah ditetapkan secara teoritis maupun operasional. Fokus utama tahap ini adalah memastikan bahwa setiap fitur memiliki kontribusi yang jelas terhadap proses klasifikasi serta tidak menimbulkan redundansi yang berlebihan. Pendekatan ini penting karena algoritma Support Vector Machine (SVM) sensitif terhadap skala data, sehingga fitur numerik perlu dinormalisasi sebelum proses pelatihan, sedangkan pada Random Forest (RF) relevansi fitur dapat diamati kembali melalui kontribusinya dalam proses pembentukan pohon keputusan.

Dengan demikian, pemilihan fitur dalam penelitian ini tidak hanya bertujuan mengurangi jumlah variabel, tetapi juga memastikan bahwa model dibangun dari fitur yang paling relevan, terukur, dan konsisten dengan tujuan penelitian, yaitu mengklasifikasikan produk ke dalam kategori diminati dan tidak diminati secara akurat.

2.3.3. Pelatihan Model dengan Algoritma SVM dan Random Forest

Pelatihan model adalah tahap inti dalam penerapan machine learning. Setelah data dipersiapkan dan fitur relevan dipilih, langkah selanjutnya adalah melatih model menggunakan algoritma pembelajaran mesin yang sesuai. Dua algoritma yang digunakan dalam penelitian ini adalah *Support Vector Machine* (SVM) dan *Random Forest* (RF). SVM bekerja dengan mencari hyperplane yang memisahkan data menjadi dua kelas, dan menggunakan kernel *functions* untuk menangani data yang tidak dapat dipisahkan secara linier (Sun et al., 2025). Di sisi lain, *Random Forest* adalah algoritma berbasis *ensemble learning* yang menggabungkan banyak *decision trees* untuk menghasilkan prediksi yang lebih stabil dan mengurangi variansi (Al Mudawi & Alazeb, 2022).

Pada tahap ini, *hyperparameter tuning* juga sangat penting. Untuk SVM, pemilihan kernel yang tepat dan penyesuaian parameter seperti C dan gamma dapat mempengaruhi kinerja model secara signifikan. Sedangkan pada *Random Forest*, jumlah pohon yang digunakan dan kedalaman setiap pohon adalah parameter penting yang mempengaruhi kemampuan model untuk mengklasifikasikan data dengan baik. Untuk mengoptimalkan kinerja, eksperimen dengan berbagai pengaturan harus dilakukan untuk menemukan konfigurasi terbaik.

2.3.4. Evaluasi Model

Setelah model dilatih, langkah berikutnya adalah melakukan evaluasi model untuk mengukur seberapa baik model dapat mengklasifikasikan data yang belum pernah dilihat sebelumnya. Pada tahap ini, beberapa metrik evaluasi yang digunakan antara lain akurasi, presisi, recall, dan F1-score (Mboweni et al., 2023). Akurasi mengukur seberapa banyak prediksi yang benar dibandingkan dengan total prediksi, sedangkan presisi dan recall memberikan wawasan lebih mendalam tentang kesalahan yang terjadi dalam klasifikasi—apakah model lebih sering menghasilkan *false positives* atau *false negatives*. *F1-score* adalah metrik yang menggabungkan presisi dan recall, memberikan gambaran yang lebih seimbang tentang kinerja model, terutama ketika data tidak seimbang (Mboweni et al., 2023) (Sun et al., 2025).

Selain itu, penting untuk melakukan cross-validation selama evaluasi untuk memastikan bahwa model dapat menggeneralisasi dengan baik pada data yang berbeda. Cross-validation membagi data pelatihan menjadi beberapa lipatan (folds) dan melatih serta menguji model pada setiap fold. Teknik ini membantu untuk menilai variabilitas kinerja model dan mencegah overfitting, yang terjadi ketika model terlalu disesuaikan dengan data pelatihan dan tidak dapat menangani data baru dengan baik (Aparajit, Y., Sanap, S., & Kumar, 2023) (Al Mudawi & Alazeb, 2022).

2.3.5. Penerapan Model

Setelah model dievaluasi dan menunjukkan kinerja yang baik, langkah terakhir adalah penerapan model. Pada tahap ini, model yang telah dilatih dan

dievaluasi diterapkan pada data transaksi atau produk yang baru. Misalnya, model dapat digunakan untuk memprediksi kategori produk yang paling diminati berdasarkan data transaksi harian yang baru masuk. Selain itu, model ini dapat digunakan untuk mengotomatiskan beberapa tugas operasional di Toko Sembako Mentari, seperti manajemen stok, perencanaan restok, dan penentuan strategi promosi.

Pada tahap penerapan, penting untuk terus memantau kinerja model untuk memastikan bahwa model tetap efektif dalam menghadapi perubahan data atau pola perilaku konsumen. Pemeliharaan model yang berkelanjutan diperlukan untuk menjaga kinerja model tetap optimal, termasuk dengan melakukan pelatihan ulang atau penyesuaian terhadap model jika diperlukan (Mboweni et al., 2023).

Proses Machine Learning untuk Klasifikasi Produk



Gambar 2. 3 Proses Machine Learning untuk Klasifikasi Produk

Grafik ini menggambarkan tahapan dalam proses machine learning untuk klasifikasi produk, dari pengumpulan data, persiapan, pelatihan, hingga evaluasi dan penerapan model.

2.4. Teknik Evaluasi Algoritma dalam Klasifikasi Produk

Evaluasi algoritma merupakan tahap penting untuk mengukur dan membandingkan kinerja model SVM dan Random Forest dalam mengklasifikasikan produk paling diminati berdasarkan data transaksi harian. Setelah model dilatih dengan data yang telah dipersiapkan, evaluasi dilakukan untuk memastikan bahwa model tersebut bekerja dengan baik dalam menghadapi data yang tidak pernah dilihat sebelumnya. Tahap evaluasi tidak hanya sekedar melihat akurasi, tetapi juga melibatkan analisis lebih mendalam melalui berbagai metrik evaluasi, seperti akurasi, presisi, recall, F1-score, serta penggunaan confusion matrix untuk menggambarkan kesalahan klasifikasi secara rinci (Rohaeti & Andriyati, 2024). Setiap metrik ini memiliki kelebihan dan kegunaan tersendiri tergantung pada jenis masalah dan dataset yang digunakan, serta pada tujuan yang ingin dicapai dalam klasifikasi produk di Toko Sembako Mentari.

2.4.1. Penggunaan Confusion Matrix dalam Evaluasi Klasifikasi

Confusion matrix adalah alat dasar dalam evaluasi klasifikasi yang digunakan untuk menggambarkan distribusi kesalahan klasifikasi yang dihasilkan oleh model. Pada dasarnya, confusion matrix menunjukkan perbandingan antara nilai yang diprediksi oleh model dan nilai yang sebenarnya dalam data uji. Matriks ini terdiri dari empat komponen utama: True Positives (TP), False Positives (FP), True Negatives (TN), dan False Negatives (FN).

1. True Positives (TP) adalah jumlah kasus yang diprediksi dengan benar sebagai positif, misalnya produk yang benar-benar diminati oleh pelanggan.

2. False Positives (FP) adalah kasus yang diprediksi sebagai positif tetapi sebenarnya negatif, misalnya produk yang diprediksi paling diminati tetapi sebenarnya tidak laris.
3. True Negatives (TN) adalah kasus yang diprediksi dengan benar sebagai negatif, misalnya produk yang diprediksi tidak diminati dan benar-benar tidak diminati.
4. False Negatives (FN) adalah kasus yang diprediksi sebagai negatif tetapi sebenarnya positif, misalnya produk yang diprediksi tidak diminati tetapi ternyata banyak dibeli.

Matriks ini memberikan gambaran yang sangat berguna mengenai jenis kesalahan yang terjadi dalam klasifikasi dan memungkinkan penyesuaian atau perbaikan model jika diperlukan. Dengan memeriksa TP, FP, TN, dan FN, kita bisa lebih memahami kesalahan apa yang perlu diperbaiki, misalnya mengurangi false positives atau false negative (Krstinić et al., 2024)(Hejmanowska et al., 2021).

Confusion matrix juga memungkinkan kita untuk mengevaluasi metrik lain yang berasal dari komponen-komponen tersebut, seperti precision dan recall, yang memberikan gambaran lebih rinci tentang kinerja model dalam mendeteksi kelas positif (Chicco et al., 2021). Oleh karena itu, confusion matrix adalah alat yang sangat berguna dalam memahami bagaimana model membuat kesalahan dan bagaimana model dapat ditingkatkan.

2.4.2. Akurasi dan Keterbatasannya

Akurasi adalah metrik evaluasi yang paling sering digunakan karena kemudahannya dalam perhitungan dan interpretasi. Akurasi mengukur proporsi dari

seluruh prediksi yang benar, baik itu True Positives (TP) maupun True Negatives (TN), terhadap seluruh prediksi yang dilakukan oleh model. Rumus untuk menghitung akurasi adalah sebagai berikut:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

Namun, meskipun akurasi sering digunakan sebagai metrik utama, ia memiliki keterbatasan yang signifikan, terutama ketika dataset tidak seimbang. Misalnya, jika data ritel memiliki lebih banyak produk yang jarang dibeli daripada produk yang sering dibeli, model dapat mencapai akurasi yang tinggi hanya dengan mengklasifikasikan sebagian besar produk sebagai tidak diminati (false negatives), sementara produk yang benar-benar diminati tidak terdeteksi dengan baik. Dalam kasus ini, meskipun akurasi tinggi, kinerja model tidak efektif dalam mendeteksi produk yang benar-benar diminati oleh pelanggan (Wang et al., 2021) (Chicco et al., 2021).

2.4.3. Precision dan Recall dalam Evaluasi Klasifikasi

Precision dan recall adalah dua metrik yang lebih mendalam untuk menilai performa model, terutama dalam kasus ketidakseimbangan kelas. Precision mengukur seberapa banyak dari prediksi positif yang benar-benar positif, sementara recall mengukur seberapa banyak dari seluruh nilai positif yang berhasil ditemukan oleh model.

Precision diukur dengan rumus:

$$\text{Precision} = \frac{TP}{TP + FP}$$

Precision berguna ketika kita ingin menghindari false positives. Dalam konteks ritel, misalnya, jika model mengklasifikasikan produk yang tidak diminati sebagai populer (false positive), ini bisa menyebabkan kesalahan dalam pengelolaan stok atau promosi yang tidak efisien.

Recall diukur dengan rumus:

$$\text{Recall} = \frac{TP}{TP + FN}$$

Recall penting ketika kita ingin memastikan bahwa produk yang benar-benar diminati oleh pelanggan dapat terdeteksi, meskipun ada kemungkinan false positives yang lebih banyak. Dalam bisnis ritel, ini berarti mengurangi jumlah produk yang tidak terdeteksi sebagai diminati (false negatives), yang dapat mengakibatkan hilangnya peluang penjualan.

F1-score adalah metrik yang menggabungkan precision dan recall, memberikan gambaran yang lebih seimbang tentang kinerja model, terutama ketika ada trade-off antara keduanya. F1-score sangat penting dalam situasi ketidakseimbangan kelas, di mana salah satu metrik (precision atau recall) mungkin lebih dominan, dan F1-score dapat memberikan ukuran yang lebih adil terhadap kinerja model secara keseluruhan (Chicco et al., 2021).

2.4.4. F1-Score sebagai Pengukur Keseimbangan

F1-score adalah harmonic mean dari precision dan recall, yang memungkinkan penilaian kinerja model yang lebih adil, terutama pada masalah dengan data tidak seimbang. Dengan menggunakan F1-score, kita mendapatkan gambaran yang lebih komprehensif mengenai bagaimana model menyeimbangkan false positives dan false negatives. Formula untuk F1-score adalah sebagai berikut:

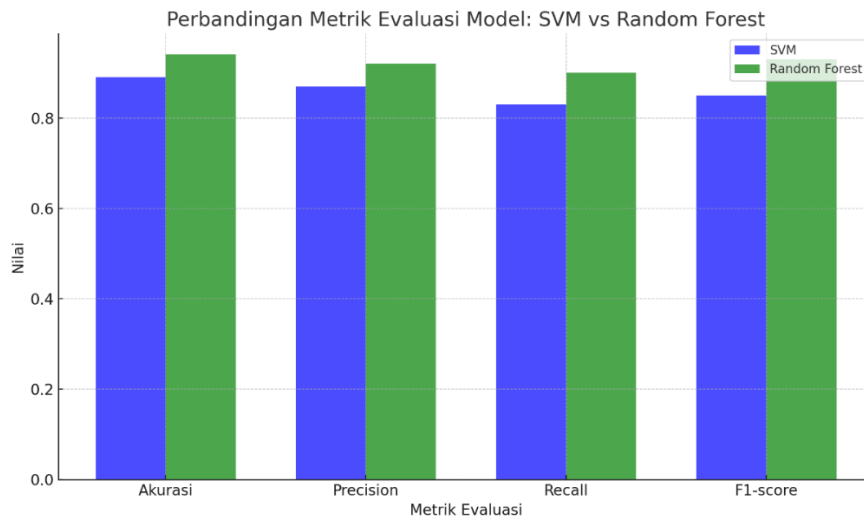
$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Karena F1-score menghukum ketidakseimbangan antara precision dan recall, ia sangat berguna dalam situasi di mana baik false positives maupun false negatives harus dikendalikan secara bersamaan. Ini membuat F1-score menjadi metrik yang lebih baik dibandingkan akurasi, terutama ketika kelas positif sangat tidak seimbang atau ketika kita menginginkan keseimbangan antara mendeteksi produk yang diminati dan menghindari kesalahan klasifikasi (Chicco et al., 2021) (Soper, 2021).

2.4.5. Area Under Curve (AUC) dan ROC AUC

Selain precision, recall, dan F1-score, ada juga metrik berbasis area yang digunakan untuk menilai kinerja model klasifikasi, yaitu Receiver Operating Characteristic (ROC) dan Precision-Recall (PR) AUC. ROC AUC mengukur kemampuan model dalam membedakan antara kelas positif dan negatif di berbagai threshold. ROC AUC dihitung dengan mengintegrasikan true positive rate terhadap false positive rate di seluruh threshold yang berbeda.

Di sisi lain, PR AUC mengukur precision terhadap recall. PR AUC lebih berguna ketika kelas positif sangat jarang, karena ROC AUC dapat memberikan gambaran yang tidak memadai ketika terjadi ketidakseimbangan kelas. PR AUC mengabaikan true negatives dan fokus pada performa model dalam mendeteksi kelas positif, sehingga memberikan informasi yang lebih berguna ketika data sangat tidak seimbang (Chicco et al., 2021).



Gambar 2. 4 Perbandingan Metrik Evaluasi Model

Grafik ini menunjukkan perbandingan antara berbagai metrik evaluasi—akurasi, precision, recall, dan F1-score untuk dua algoritma klasifikasi: SVM dan Random Forest. Grafik ini membantu untuk melihat secara langsung bagaimana kedua algoritma berperforma dengan metrik yang berbeda, dan memberikan gambaran yang lebih komprehensif tentang kekuatan dan kelemahan masing-masing algoritma.

2.5. Alat Bantu Pemrograman dan Tools Pendukung Penelitian

Dalam penelitian ini, penggunaan alat bantu pemrograman dan pustaka (libraries) yang tepat sangat penting untuk memastikan bahwa penelitian dapat dilakukan dengan efisien dan hasilnya dapat diulang oleh peneliti lain di masa depan. Python digunakan sebagai bahasa utama karena menyediakan pustaka lengkap seperti scikit-learn, pandas, matplotlib, dan seaborn yang mendukung seluruh tahapan pengembangan model SVM dan RF untuk analisis data transaksi harian, mulai dari pengumpulan data, preprocessing, pelatihan model, hingga evaluasi dan penerapan model. Di samping Python, pustaka-pustaka populer seperti

scikit-learn, pandas, dan matplotlib digunakan untuk berbagai keperluan dalam penelitian ini, mulai dari pemrosesan data hingga visualisasi hasil eksperimen. Jupyter Notebook juga digunakan sebagai platform interaktif yang memungkinkan peneliti untuk menulis, menguji, dan memodifikasi kode Python secara langsung dalam satu lingkungan yang dapat didokumentasikan dan dibagikan dengan mudah (TOPSAKAL, 2023).

2.5.1. Python Ekosistem yang Lengkap untuk Machine Learning

Python telah menjadi bahasa pemrograman yang dominan dalam dunia data science dan machine learning. Keunggulannya terletak pada ekosistem pustaka yang sangat luas dan kemampuannya untuk menangani berbagai jenis masalah klasifikasi, baik yang melibatkan data terstruktur, time-series, maupun data tidak terstruktur seperti teks dan gambar. Beberapa pustaka Python yang paling sering digunakan untuk tugas machine learning antara lain scikit-learn, TensorFlow, Keras, dan XGBoost, yang semuanya menyediakan implementasi yang efisien dari berbagai algoritma pembelajaran mesin yang sering digunakan (Althoff et al., 2025) (Alghamdi & Javaid, 2022).

Keuntungan besar Python adalah kemampuannya untuk memfasilitasi end-to-end workflow dalam machine learning, mulai dari data ingestion dan preprocessing, hingga modeling, visualization, dan deployment. Dengan Python, peneliti dapat melakukan eksplorasi data, membangun model, dan melakukan analisis hasil dalam satu bahasa yang konsisten, yang mempermudah kolaborasi antar tim yang berbeda keahlian, seperti tim data engineer dan tim data scientist. Python juga memungkinkan integrasi dengan berbagai platform pengolahan data

besar seperti Apache Spark, serta framework pengembangan aplikasi seperti Django, memungkinkan transisi yang mulus dari eksperimen machine learning ke sistem produksi (Soper, 2021) (Mboweni et al., 2023).

2.5.2. Pustaka Python yang Mendukung Proses Machine Learning

scikit-learn adalah pustaka utama yang digunakan dalam penelitian ini untuk implementasi algoritma pembelajaran mesin seperti Support Vector Machine (SVM) dan Random Forest (RF). Salah satu alasan utama penggunaan scikit-learn adalah kemampuannya untuk menyediakan implementasi yang telah teruji dari algoritma-algoritma klasik yang digunakan dalam klasifikasi dan regresi. Selain itu, scikit-learn juga dilengkapi dengan alat untuk preprocessing, cross-validation, dan evaluasi model, yang semuanya penting untuk memastikan bahwa model yang dibangun dapat menghasilkan prediksi yang akurat dan andal (Cheng et al., 2023) (Soper, 2021).

Di sisi lain, pandas adalah pustaka yang sangat berguna untuk manipulasi data tabular. Dalam konteks Toko Sembako Mentari, pandas digunakan untuk pembersihan data dan persiapan fitur, seperti mengimputasi nilai yang hilang, mengubah tipe data, dan menggabungkan beberapa sumber data menjadi satu dataset yang siap digunakan untuk pelatihan model. Dengan pandas, peneliti dapat dengan mudah mengelola dan memanipulasi dataset besar dengan menggunakan berbagai fungsi yang efisien untuk transformasi dan agregasi data (Singh et al., 2024) (Lapina et al., 2024).

Selain scikit-learn dan pandas, matplotlib dan seaborn digunakan untuk visualisasi data dan hasil eksperimen. matplotlib adalah pustaka dasar yang sangat

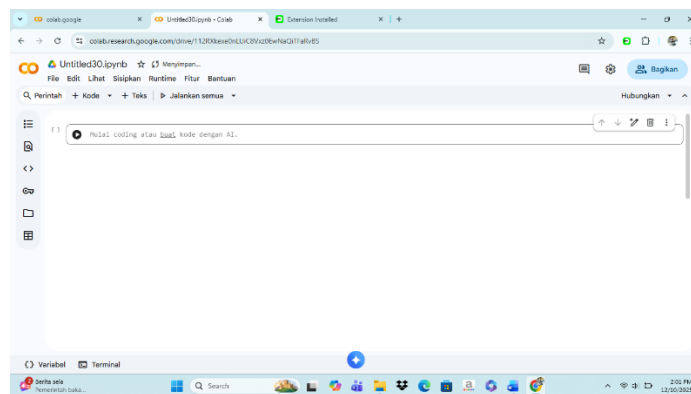
fleksibel untuk membuat grafik dan diagram yang digunakan dalam exploratory data analysis (EDA), sementara seaborn memberikan kemampuan visualisasi statistik yang lebih tinggi, seperti membuat heatmap atau pairplots yang memudahkan peneliti dalam menganalisis hubungan antar fitur data (Kiranbala Nongthombam1, 2024). Visualisasi ini memungkinkan peneliti untuk mendapatkan pemahaman yang lebih baik mengenai struktur dan distribusi data sebelum membangun model.

2.5.3. Google Colab sebagai Platform Interaktif untuk Eksperimen

Google Colaboratory (Google Colab) merupakan layanan komputasi awan berbasis notebook yang disediakan oleh Google dan memungkinkan pengguna menulis serta mengeksekusi kode Python langsung melalui peramban tanpa perlu instalasi perangkat lunak tambahan di sisi lokal. Google Colab dibangun di atas lingkungan Jupyter Notebook dan menyediakan akses gratis ke sumber daya komputasi seperti GPU dan TPU, sehingga sangat sesuai untuk eksperimen machine learning, deep learning, serta analisis data berskala menengah hingga besar (Vallejo et al., 2022).

Dari sisi teknis, Google Colab menawarkan beberapa keunggulan yang relevan bagi penelitian ini. Pertama, lingkungan pemrograman sudah terkonfigurasi dengan berbagai pustaka Python yang umum digunakan, seperti NumPy, pandas, matplotlib, scikit-learn, hingga TensorFlow dan PyTorch (Haana Udtari Anjani et al., 2024). Hal ini mengurangi beban peneliti dalam melakukan instalasi dan konfigurasi manual yang berpotensi menimbulkan masalah kompatibilitas. Kedua, dukungan GPU/TPU memungkinkan proses pelatihan model yang relatif berat

dijalankan lebih cepat dibandingkan hanya mengandalkan CPU standar, sehingga mempercepat siklus eksperimen dan tuning model. Penelitian (Carneiro et al., 2018) menunjukkan bahwa Google Colab layak digunakan sebagai sarana percepatan aplikasi deep learning karena kombinasi antara ketersediaan GPU dan lingkungan yang telah terkonfigurasi dengan baik.




Gambar 2. 5 Tampilan Google Colab

2.5.4. Alat Bantu untuk Analisis dan Visualisasi Data

Salah satu keunggulan besar menggunakan Python adalah kemampuannya untuk mengintegrasikan berbagai pustaka dan alat bantu yang berbeda dalam satu pipeline yang mulus. Misalnya, dalam penelitian ini, OpenCV digunakan untuk pemrosesan gambar dalam kasus di mana data produk diwakili oleh gambar. Pustaka ini memungkinkan peneliti untuk mengekstrak fitur gambar yang relevan, yang kemudian dapat digunakan sebagai input untuk model machine learning seperti SVM dan Random Forest. Ketika menggabungkan OpenCV untuk ekstraksi fitur dengan scikit-learn untuk klasifikasi, peneliti dapat membuat pipeline yang efisien untuk tugas-tugas pengenalan pola berbasis gambar (Hussein Ali et al., 2021)(Cujar-Rosero et al., 2021).

Selain itu, ketika machine learning berhadapan dengan dataset yang lebih besar atau kompleks, penggunaan pustaka tambahan seperti XGBoost atau CatBoost dapat membantu meningkatkan kinerja model. Pustaka-pustaka ini digunakan untuk gradient boosting, yang merupakan metode yang sangat kuat untuk menangani data tabular yang lebih kompleks, seperti yang sering dijumpai dalam analisis penjualan atau peramalan stok produk (Bao & Bambil, 2021)(Althoff et al., 2025). Dengan mengintegrasikan pustaka-pustaka ini, Toko Sembako Mentari dapat memanfaatkan model yang lebih kompleks untuk prediksi yang lebih akurat.

Python juga memungkinkan integrasi model ke dalam aplikasi produksi melalui framework web seperti Django. Dengan demikian, hasil dari eksperimen dan prototipe model dapat dengan mudah diubah menjadi aplikasi yang dapat digunakan langsung oleh tim operasional atau pelanggan. Penggunaan Django untuk menerapkan model ke dalam web application memungkinkan penerapan yang lebih praktis dan efisien dalam lingkungan bisnis yang dinamis(Garg et al., 2021)(SETHI et al., 2023).



Gambar 2. 6 Visualisasi Data

2.6. Penelitian Terdahulu dan Kelebihan Penelitian

Tabel 2. 1 Penelitian Terdahulu

Peneliti	Judul	Tahun	Data dan Algoritma	Hasil
(Vu Giang et al., 2025)	Mengevaluasi potensi data satelit dan model pembelajaran mesin untuk klasifikasi tutupan lahan dalam mendukung inventarisasi emisi.	2025	Data satelit, Random Forest, Support Vector Machine	Mengevaluasi klasifikasi tutupan lahan dengan akurasi tinggi menggunakan model pembelajaran mesin.
(Fatholouloumi et al., 2022)	Skenario berbasis fusi yang inovatif untuk meningkatkan akurasi pemetaan tanaman lahan.	2022	Data tanaman lahan, Random Forest, SVM	Peningkatan akurasi pemetaan lahan pertanian dengan penggabungan berbagai metode pembelajaran mesin.
(Chen et al., 2023)	Analisis tekstur MRI multimodal berbasis pembelajaran mesin untuk menilai fungsi ginjal dan fibrosis pada nefropati diabetik.	2023	Data MRI multimodal, Mesin Vektor Pendukung	Penilaian fungsi ginjal dan fibrosis yang akurat menggunakan MRI multimodal dan pembelajaran mesin.
(Bin et al., 2023)	Studi tentang prediksi tingkat kelulusan gamma dalam verifikasi dosimetri radioterapi modulasi intensitas menggunakan model pembelajaran mesin berdasarkan kompleksitas rencana.	2023	Data radioterapi, Random Forest, Support Vector Machine	Prediksi tingkat kelulusan Gamma menggunakan pembelajaran mesin untuk radioterapi
(Farias et al., 2023)	Perbedaan terkait jenis kelamin dalam struktur retina pada orang dewasa muda: pendekatan pembelajaran mesin.	2023	Data retina, Random Forest, Support Vector Machine	Pembelajaran mesin diterapkan untuk menganalisis perbedaan retina terkait jenis kelamin pada orang dewasa muda.

Penelitian Ini	Klasifikasi Produk di Toko Sembako Mentari Menggunakan SVM dan Random Forest	2025	Data transaksi produk, SVM, Random Forest	Dalam tahap penelitian
----------------	------------------------------------------------------------------------------	------	-------------------------------------------	------------------------

Penelitian ini memiliki kebaruan pada penerapan perbandingan algoritma Support Vector Machine dan Random Forest untuk klasifikasi produk paling diminati pada data transaksi harian UMKM berskala kecil, yaitu Toko Sembako Mentari. Berbeda dengan banyak penelitian sebelumnya yang lebih banyak dilakukan pada sektor skala besar atau domain non-ritel, penelitian ini berfokus pada karakteristik data transaksi yang sederhana, terbatas, dan dekat dengan kebutuhan operasional usaha kecil.

Selain membandingkan kinerja kedua algoritma, penelitian ini juga menekankan identifikasi variabel transaksi yang berperan dalam proses klasifikasi, yaitu jumlah pembelian, harga satuan, dan frekuensi transaksi. Dengan demikian, kontribusi utama penelitian ini terletak pada penerapan praktis machine learning dalam membantu pengelolaan stok dan pengambilan keputusan berbasis data pada lingkungan ritel kecil.

2.7. Flowchart Klasifikasi Produk Menggunakan Machine Learning

Flowchart merupakan alat visual yang digunakan untuk menggambarkan alur kerja dalam suatu proses secara sistematis. Dalam konteks penelitian klasifikasi produk yang menggunakan algoritma machine learning, flowchart dapat membantu memvisualisasikan langkah-langkah yang terlibat dalam seluruh proses penelitian. Dengan visualisasi yang jelas, flowchart juga dapat mempercepat pemahaman bagi berbagai pemangku kepentingan yang terlibat dalam penelitian, mulai dari

pengumpulan data hingga penerapan model yang telah dilatih. Pada bagian ini, akan dibahas bagaimana flowchart dapat menggambarkan langkah-langkah yang digunakan dalam penelitian ini, mulai dari pengumpulan data, persiapan data, penerapan algoritma SVM (Support Vector Machine) dan Random Forest (RF), hingga evaluasi dan penerapan model untuk memprediksi produk yang paling diminati.

2.7.1. Pengumpulan Data dan Persiapan Data

Langkah pertama dalam flowchart penelitian ini adalah pengumpulan data transaksi harian dari Toko Sembako Mentari. Data yang dikumpulkan mencakup informasi produk, harga, jumlah yang dibeli, waktu transaksi, serta informasi tambahan lainnya yang dapat mempengaruhi minat pelanggan terhadap produk tertentu. Data ini bisa berupa data tabular yang terstruktur dengan kolom-kolom seperti ID produk, kategori produk, jumlah yang dibeli, dan harga.

Setelah pengumpulan data, langkah berikutnya dalam flowchart adalah pembersihan dan persiapan data. Pada tahap ini, data yang dikumpulkan akan diperiksa dan dibersihkan untuk mengatasi masalah seperti data yang hilang, duplikasi data, dan outlier. Proses ini juga mencakup normalisasi data jika diperlukan, serta transformasi data ke dalam format yang dapat diterima oleh algoritma machine learning yang akan diterapkan, seperti encoding kategorikal untuk data produk yang bersifat kategorikal dan scaling untuk data numerik (Lohit et al., 2022)(Yamaguchi et al., 2022).

2.7.2. Pembagian Data (Training dan Testing Set)

Setelah data dipersiapkan, langkah berikutnya dalam flowchart adalah pembagian data menjadi dua bagian utama: training set dan testing set. Training set digunakan untuk melatih model machine learning, sementara testing set digunakan untuk mengevaluasi kinerja model yang telah dilatih. Pembagian data ini bertujuan untuk menghindari overfitting, yaitu ketika model terlalu menyesuaikan diri dengan data pelatihan dan gagal menggeneralisasi pada data baru (Bettega et al., 2021) (Vu Giang et al., 2025).

2.7.3. Penerapan Algoritma (SVM dan RF)

Pada tahap penerapan algoritma, flowchart menunjukkan dua jalur terpisah untuk SVM dan Random Forest. SVM digunakan untuk mencari hyperplane terbaik yang memisahkan kelas-kelas produk berdasarkan fitur yang tersedia, sementara Random Forest membangun banyak pohon keputusan dan menggabungkan hasil dari setiap pohon untuk membuat prediksi yang lebih akurat. Keduanya merupakan algoritma yang kuat dalam menangani masalah klasifikasi, namun mereka memiliki pendekatan yang berbeda dalam memproses dan mengklasifikasikan data (Fatholouloumi et al., 2022)(Álvarez Gutiérrez et al., 2022).

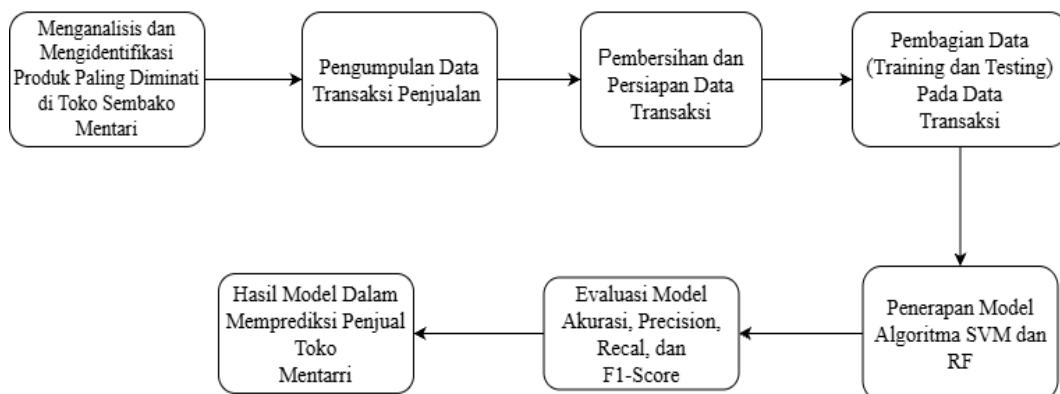
2.7.4. Evaluasi Model

Setelah model diterapkan, langkah berikutnya adalah evaluasi model. Dalam flowchart, evaluasi ini dilakukan menggunakan testing set yang telah dipisahkan sebelumnya. Model diuji dengan metrik evaluasi seperti akurasi, precision, recall, dan F1-score, yang memberikan gambaran tentang seberapa baik model dapat mengklasifikasikan produk yang benar (Helmi et al., 2024). Selain itu,

confusion matrix juga digunakan untuk lebih memahami kesalahan klasifikasi yang terjadi, seperti false positives dan false negatives, yang bisa membantu dalam memperbaiki model di iterasi berikutnya.

2.7.5. Penerapan Model untuk Prediksi

Setelah model dievaluasi, langkah terakhir dalam flowchart adalah penerapan model untuk prediksi produk yang paling diminati. Berdasarkan hasil evaluasi dan metrik yang diperoleh, model terbaik, baik itu SVM atau Random Forest, digunakan untuk memprediksi produk-produk yang kemungkinan besar akan diminati oleh konsumen berdasarkan data transaksi yang ada.



Flowchart ini menggambarkan langkah-langkah penelitian dari pengumpulan data transaksi harian, preprocessing, pembagian data, penerapan algoritma SVM dan Random Forest, hingga evaluasi kinerja model, sehingga proses penelitian dapat direplikasi dan divalidasi dengan hasil yang konsisten(Floriano et al., 2023)(Bautista-Valarezo et al., 2023).