

KLASIFIKASI KATEGORI PRODUK PEMBELIAN BERIKUTNYA PADA DATA TRANSAKSI RITEL MENGGUNAKAN RANDOM FOREST DENGAN PENDEKATAN RFM DAN FITUR SEKUENSIAL

Muhammad Miqdad Al Ghifary¹; Dian Ade Kurnia²; Yudhistira Arie Wijaya³; Heliyanti Susana⁴; Ryan Hamonangan⁵;

Program Studi Teknik Informatika¹⁴⁵
Program Studi Manajemen Informatika²⁴⁵
Program Studi Sistem Informasi³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
muhammadmiqdad40@gmail.com

(*) Corresponding Author : muhammadmiqdad40@gmail.com
Received: date; Accepted: date; Published: date

Abstract—This study examines the use of Random Forest to perform classification of the next product purchase category in physical retail transaction data by applying RFM features and sequential features. The purpose of this research is to develop an accurate prediction model and compare its performance with a baseline model to achieve an improvement in F1-score. The Random Forest algorithm is applied using the RFM approach combined with the last purchased category and purchase interval as key predictors. Retail transaction data are processed to construct next-category labels so that the model can learn from customer behavior sequences. The results show that the model reaches an accuracy of 38.16%, with varying precision, recall, and F1-scores across categories due to class imbalance. Cross-validation indicates that the model is stable without signs of overfitting. Feature importance analysis reveals that recency, frequency, monetary, last category, and purchase interval play dominant roles in prediction, aligning with consumer behavior theory. These findings demonstrate that feature-based methods remain effective for predicting customer behavior in physical retail settings. This research contributes empirical evidence supporting the relevance of Random Forest for next-purchase prediction and provides practical benefits for strategic decision-making, particularly in promotion planning and inventory management.

Keywords: Random Forest; RFM; product category classification; next purchase prediction; retail transaction data.

Abstrak- Penelitian ini menilai penggunaan Random Forest untuk melakukan klasifikasi kategori produk pembelian berikutnya pada data transaksi ritel fisik dengan memanfaatkan fitur RFM dan fitur sekuensial. Tujuan penelitian ini adalah membangun model prediksi yang akurat serta membandingkan kinerjanya dengan model dasar untuk mencapai peningkatan F1-score. Penelitian ini menggunakan algoritma Random Forest dengan pendekatan RFM yang dipadukan dengan informasi kategori pembelian terakhir dan interval pembelian sebagai fitur utama. Data transaksi ritel diolah untuk membentuk label kategori berikutnya sehingga model dapat belajar dari urutan perilaku pelanggan. Hasil penelitian menunjukkan bahwa model mencapai akurasi 38,16% dengan variasi nilai precision, recall, dan F1-score pada tiap kategori akibat ketidakseimbangan kelas. Uji cross-validation menunjukkan model stabil tanpa tanda overfitting. Analisis feature importance menampilkan bahwa recency, frequency, monetary, kategori terakhir, dan pola interval pembelian memiliki peran dominan dalam prediksi, yang sejalan dengan teori perilaku konsumen. Temuan ini membuktikan bahwa metode berbasis fitur tetap efektif untuk memprediksi perilaku pelanggan pada ritel fisik. Penelitian ini memberi kontribusi akademik berupa bukti empiris mengenai relevansi pendekatan Random Forest pada prediksi pembelian berikutnya serta memberikan manfaat praktis bagi pengambilan keputusan strategis, khususnya dalam perencanaan promosi dan pengelolaan persediaan.

Keyword: *Random Forest; RFM; klasifikasi produk; prediksi pembelian berikutnya; data transaksi ritel.*

INTRODUCTION

Perkembangan teknologi informasi dalam era ekonomi digital telah memberikan dampak signifikan terhadap operasional industri ritel. Pemanfaatan data transaksi pelanggan menjadi komponen strategis dalam upaya meningkatkan efektivitas pengambilan keputusan, khususnya pada perencanaan promosi, personalisasi layanan, dan manajemen inventori. Kemampuan organisasi dalam mengolah dan menganalisis data tersebut menjadi kunci untuk memahami pola perilaku pelanggan secara lebih komprehensif.

Machine learning merupakan salah satu pendekatan yang banyak digunakan dalam menganalisis perilaku pelanggan karena kemampuannya mengekstraksi pola-pola kompleks dari data berukuran besar. Berbagai penelitian menunjukkan bahwa model prediktif, seperti model sekuensial maupun model ensemble, telah digunakan untuk memprediksi pola pembelian konsumen serta faktor-faktor yang memengaruhinya. Sebagai contoh, model GRU digunakan untuk memprediksi keranjang pembelian berikutnya (van Maasakkers et al., 2023), sementara integrasi teori perilaku dan machine learning diterapkan untuk menganalisis sinyal perilaku konsumen pada media sosial (Azad et al., 2023). Selain itu, penelitian lain menunjukkan pemanfaatan data web analytics dalam mengklasifikasi tingkat keterlibatan belanja daring (Gkikas & Theodoridis, 2024) serta penggunaan model Random Forest yang dikombinasikan dengan Explainable AI (Chen et al., 2023).

Meskipun demikian, sebagian besar penelitian terdahulu lebih fokus pada konteks e-commerce dan clickstream, sedangkan pemanfaatan data transaksi ritel fisik untuk prediksi kategori produk pembelian berikutnya masih relatif jarang dilakukan. Karakteristik data transaksi ritel yang cenderung heterogen, tidak teratur, dan melibatkan banyak kategori produk menuntut metode analitik yang tidak hanya akurat, tetapi juga stabil dan mudah diinterpretasikan oleh pengguna bisnis.

Random Forest merupakan salah satu algoritma yang relevan dalam konteks ini karena kemampuannya menangani data multivariat, ketahanannya terhadap noise, serta kemampuannya memberikan interpretasi melalui feature importance. Namun, penelitian yang secara khusus mengkaji efektivitas Random Forest dalam memprediksi kategori pembelian berikutnya

berdasarkan data transaksi ritel fisik masih sangat terbatas.

MATERIALS AND METHODS

Data Preprocessing

Proses data preprocessing dilakukan untuk memastikan kualitas dan konsistensi data sebelum memasuki tahap pemodelan. Langkah pertama adalah data cleaning, yaitu menghapus missing values, menghilangkan data duplikat, serta menangani outlier agar tidak memengaruhi hasil analisis. Selanjutnya dilakukan transformasi data, yang mencakup proses encoding variabel kategorikal menggunakan LabelEncoder dan konversi variabel temporal agar dapat diproses secara numerik oleh model. Tahap berikutnya adalah filtering data, yaitu memilih data pelanggan yang masih aktif dan relevan sehingga hanya informasi yang valid dan mendukung analisis yang digunakan dalam proses klasifikasi. Proses preprocessing ini memastikan data berada dalam kondisi optimal untuk menghasilkan model prediksi yang akurat. Proses pra-pemrosesan meliputi:

- a) Data Cleaning: menghapus missing values, data duplikat, dan outlier.
- b) Transformasi Data:
 - 1) Encoding kategori menggunakan LabelEncoder
 - 2) Konversi variabel temporal
- c) Filtering Data: memilih data pelanggan yang masih aktif atau relevan

Pembagian Dataset

Tahap pembagian dataset merupakan langkah penting dalam proses pemodelan karena menentukan bagaimana model belajar dan diuji terhadap data yang belum pernah dilihat sebelumnya. Pada penelitian ini, dataset dibagi menjadi dua bagian menggunakan metode train-test split, yaitu 80% sebagai data latih dan 20% sebagai data uji. Proporsi ini dipilih untuk memberikan jumlah data yang cukup bagi model dalam mempelajari pola pembelian pelanggan, sekaligus menyediakan data yang representatif untuk menguji kemampuan generalisasi model. Pembagian ini memastikan bahwa model tidak hanya menghafal data, tetapi mampu memprediksi kategori pembelian pelanggan secara akurat pada data baru.

Selain itu, digunakan parameter `random_state = 42` untuk menjaga konsistensi

proses pembagian data. Parameter ini memungkinkan reproduktibilitas hasil penelitian, sehingga setiap kali proses train-test split dijalankan, data terbagi dengan cara yang sama dan hasil evaluasi model tetap konsisten. Dengan pembagian dataset yang terstruktur dan terkontrol seperti ini, proses pelatihan dan pengujian model menjadi lebih valid serta memberikan dasar yang kuat untuk menilai kinerja algoritma klasifikasi yang digunakan.

Feature Engineering

Feature engineering merupakan tahapan penting dalam proses pemodelan machine learning karena menentukan kualitas informasi yang digunakan oleh algoritma untuk melakukan prediksi. Pada penelitian ini, feature engineering dilakukan dengan membangun dan mengolah sejumlah fitur yang mampu merepresentasikan perilaku pembelian pelanggan secara lebih mendalam. Salah satu pendekatan utama yang digunakan adalah pembentukan fitur RFM (Recency, Frequency, Monetary) yang masing-masing menggambarkan seberapa baru pelanggan melakukan transaksi, seberapa sering aktivitas pembelian dilakukan, serta berapa besar nilai belanja yang telah dikeluarkan. Ketiga fitur ini memberikan gambaran komprehensif mengenai nilai dan pola interaksi pelanggan dengan sistem.

Selain fitur RFM, penelitian ini juga menyertakan fitur tambahan seperti *Last_Purchase_Category* dan *Last_Purchase_Quantity* yang memberikan konteks langsung mengenai perilaku pembelian terakhir pelanggan. Fitur ini menjadi indikator penting untuk memahami kecenderungan pelanggan dalam memilih kategori produk tertentu. Seluruh fitur tersebut kemudian diproses dalam format numerik agar dapat dibaca oleh algoritma machine learning, termasuk melalui teknik encoding untuk variabel kategorikal. Dengan melakukan feature engineering yang tepat dan terstruktur, data yang digunakan menjadi lebih informatif dan relevan, sehingga model klasifikasi mampu mempelajari pola dengan lebih baik dan menghasilkan prediksi kategori pembelian yang lebih akurat.

Fitur RFM

Fitur RFM digunakan untuk menggambarkan dan memahami perilaku pembelian pelanggan melalui tiga komponen utama, yaitu Recency, yang menunjukkan interval waktu sejak transaksi terakhir dilakukan; Frequency, yang mencerminkan seberapa sering pelanggan melakukan pembelian; serta Monetary, yang merepresentasikan total nilai belanja yang telah dikeluarkan pelanggan. Ketiga fitur ini memberikan gambaran kuantitatif

mengenai tingkat aktivitas dan nilai pelanggan dalam sistem. Untuk meningkatkan konsistensi dan stabilitas data, proses skoring atau normalisasi dapat diterapkan sehingga setiap variabel memiliki rentang nilai yang seimbang dan lebih mudah diproses oleh algoritma machine learning dalam tahap pemodelan. Fitur RFM dihitung untuk memahami perilaku pembelian pelanggan:

- a) *Recency*: interval waktu sejak pembelian terakhir
- b) *Frequency*: total frekuensi pembelian
- c) *Monetary*: total belanja
- d) Skoring atau normalisasi dapat diterapkan untuk stabilisasi nilai

Fitur Pembelian Terakhir (Last Purchase Feature)

Variabel *Last_Purchase_Category* dan *Last_Purchase_Quantity* digunakan sebagai indikator langsung untuk menangkap kecenderungan pembelian pelanggan berdasarkan transaksi terakhir yang mereka lakukan. *Last_Purchase_Category* memberikan informasi mengenai jenis produk yang paling baru dibeli, sehingga dapat menjadi petunjuk awal terhadap preferensi kategori yang mungkin dipilih kembali oleh pelanggan. Sementara itu, *Last_Purchase_Quantity* menunjukkan jumlah item yang dibeli pada transaksi terakhir, yang dapat mencerminkan intensitas kebutuhan atau pola konsumsi pelanggan. Kedua variabel ini bersama-sama membantu model memahami perilaku pembelian terkini sebagai dasar prediksi kategori pembelian berikutnya. Menggunakan variabel:

- a) *Last_Purchase_Category*
- b) *Last_Purchase_Quantity*

Sebagai indikator langsung kecenderungan pembelian pelanggan.

Perancangan Model Klasifikasi

Perancangan model klasifikasi dilakukan untuk memprediksi kategori pembelian berikutnya berdasarkan pola perilaku pelanggan yang terekam dalam dataset. Pada tahap ini, dua algoritma utama digunakan, yaitu *Decision Tree* sebagai model baseline dan *Random Forest* sebagai model utama dengan performa yang lebih stabil. Proses perancangan dimulai dengan menyiapkan fitur hasil preprocessing, kemudian melatih model menggunakan data latih untuk mempelajari hubungan antara variabel input dan kategori pembelian. Parameter seperti jumlah pohon pada *Random Forest* serta kedalaman pohon pada *Decision Tree* dikonfigurasi untuk mengoptimalkan kinerja model. Setelah pelatihan, model diuji menggunakan data uji untuk mengevaluasi kemampuan generalisasinya. Melalui tahapan perancangan ini, model dapat membangun representasi yang akurat terhadap pola pembelian

pelanggan sehingga mampu mengklasifikasikan kategori produk secara lebih tepat.

Model Decision Tree

Model Decision Tree digunakan sebagai baseline dalam penelitian ini karena sifatnya yang sederhana, mudah diinterpretasikan, dan mampu memberikan gambaran awal mengenai pola klasifikasi dalam data. Model ini dilatih menggunakan data latih dengan menerapkan parameter default tanpa penyesuaian khusus, sehingga hasil yang diperoleh mencerminkan performa dasar dari struktur pohon keputusan. Setelah proses pelatihan, model dievaluasi menggunakan metrik akurasi serta classification report, yang mencakup nilai precision, recall, dan F1-score untuk setiap kategori. Evaluasi ini memberikan gambaran awal mengenai kemampuan model dalam membedakan kelas-kelas pembelian pelanggan dan menjadi acuan untuk membandingkan peningkatan kinerja pada model yang lebih kompleks seperti Random Forest. Decision Tree digunakan sebagai baseline model:

- Parameter default*
- Dilatih menggunakan data latih*
- Dievaluasi menggunakan akurasi dan classification report*

Model Random Forest

Model Random Forest digunakan sebagai model utama karena kemampuannya dalam menangani data berdimensi campuran dan menghasilkan prediksi yang lebih stabil dibandingkan model tunggal seperti Decision Tree. Model ini dibangun menggunakan 200 pohon keputusan ($n_estimators = 200$) dengan kedalaman maksimum tidak dibatasi ($max_depth = None$), sehingga setiap pohon memiliki fleksibilitas penuh untuk mempelajari pola dari data. Parameter $random_state = 42$ diterapkan untuk menjaga konsistensi dan reproduktibilitas hasil. Sama seperti Decision Tree, Random Forest dilatih dan diuji menggunakan dataset yang sama sehingga memungkinkan perbandingan performa yang objektif. Dengan konfigurasi ini, Random Forest mampu memanfaatkan pendekatan ensemble untuk meningkatkan akurasi dan ketahanan terhadap overfitting, menjadikannya model yang lebih unggul dalam memprediksi kategori pembelian pelanggan. Random Forest digunakan sebagai model utama:

- $n_estimators = 200$
- $max_depth = None$
- $random_state = 42$
- Dilatih dan diuji menggunakan data yang sama dengan Decision Tree

RESULTS AND DISCUSSION

Pemodelan Klasifikasi

Pada tahap ini dilakukan proses pemodelan menggunakan dua algoritma klasifikasi, yaitu Decision Tree dan Random Forest. Kedua algoritma tersebut dipilih untuk dibandingkan performanya dalam memprediksi kategori produk pembelian berikutnya berdasarkan atribut Recency, Frequency, Monetary, dan Last_Purchase_Quantity. Seluruh proses pemodelan didasarkan pada kode program yang telah disiapkan, dimulai dari pembagian data ke dalam set pelatihan dan pengujian, pelatihan model, hingga evaluasi hasil prediksi.

Pemodelan menggunakan **Decision Tree** dilakukan terlebih dahulu sebagai baseline untuk melihat performa awal tanpa teknik ensemble. Algoritma ini menghasilkan struktur pohon keputusan yang diharapkan mampu mengenali pola sederhana dari data. Selanjutnya, dilakukan pemodelan menggunakan **Random Forest**, yang merupakan pengembangan dari Decision Tree dengan menggabungkan sejumlah pohon keputusan sekaligus untuk meningkatkan akurasi dan stabilitas prediksi.

Import Library dan Load Dataset

Pada tahap awal, proses dimulai dengan melakukan import library yang diperlukan, seperti pandas untuk pengolahan data serta scikit-learn untuk kebutuhan pemodelan dan evaluasi. Selanjutnya, dataset hasil transformasi dimuat ke dalam lingkungan pemrograman.

```
# 2. LOAD DATASET
# =====
df = pd.read_excel("/content/DATA_FIX.xlsx")

print("Preview Data:")
print(df.head())
```

Gambar 1 Coding Import Dataset

Output

```
... Preview Data:
   Recency  Frequency  Monetary  Last_Purchase_Category  Last_Purchase_Quantity
0        39          1        150                    Beauty                      3
1        309         1        1000                   Clothing                      2
2        354         1         30                   Electronics                      1
3        226         1        500                   Clothing                      1
4        241         1        100                    Beauty                      2
```

Gambar 3 Hasil Output Dataset

Dataset memuat empat fitur utama dan satu label kategori produk. Seluruh data sudah dalam format numerik kecuali label yang nantinya diencode. Tampilan preview menunjukkan bahwa dataset siap digunakan untuk proses pemodelan.

Pembagian Data Train-Test

Pada tahap ini, dataset dibagi menjadi dua bagian, yaitu data latih dan data uji, dengan proporsi 80%

untuk pelatihan model dan 20% untuk pengujian. Pembagian ini dilakukan untuk memastikan bahwa model dapat dievaluasi menggunakan data yang belum pernah dilihat sebelumnya sehingga hasil prediksi lebih objektif.

```
# =====
# 4. SPLIT DATA TRAIN & TEST
# =====
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.2, random_state=42
)
```

Gambar 4 coding Split Dataset

Dataset dibagi menjadi 80% data latih dan 20% data uji. Teknik ini memastikan proses evaluasi dilakukan secara objektif.

Hasil Model Decision Tree

Hasil pemodelan menggunakan algoritma Decision Tree menunjukkan nilai akurasi sebesar 0.335, dengan performa yang bervariasi pada setiap kategori produk berdasarkan nilai precision, recall, dan f1-score. Tabel evaluasi yang dihasilkan menggambarkan bagaimana model mengenali pola pada kategori Beauty, Clothing, dan Electronics dari data uji.

```
# 5. MODEL DECISION TREE
# =====
dt_model = DecisionTreeClassifier(random_state=42)
dt_model.fit(X_train, y_train)

dt_pred = dt_model.predict(X_test)
```

Gambar 5 Coding Model Decision Tree

Output

```
=== DECISION TREE RESULTS ===
Accuracy: 0.335
```

	precision	recall	f1-score	support
Beauty	0.33	0.24	0.28	67
Clothing	0.32	0.39	0.35	71
Electronics	0.36	0.37	0.37	62
accuracy			0.34	200
macro avg	0.34	0.33	0.33	200
weighted avg	0.34	0.34	0.33	200

Gambar 6 Output Model Decision Tree

Hasil Model Random Forest

Pemodelan menggunakan algoritma Random Forest menghasilkan akurasi sebesar 0.35, sedikit lebih tinggi dibandingkan Decision Tree. Hasil evaluasi menunjukkan nilai precision, recall, dan f1-score yang lebih stabil pada setiap kategori produk, mencerminkan kemampuan model dalam memanfaatkan kombinasi banyak pohon keputusan.

```
# 6. MODEL RANDOM FOREST
# =====
rf_model = RandomForestClassifier(
    n_estimators=200,
    max_depth=None,
    random_state=42
)
rf_model.fit(X_train, y_train)

rf_pred = rf_model.predict(X_test)
```

Gambar 7 Coding Model random Forest

Output

```
=== RANDOM FOREST RESULTS ===
Accuracy: 0.35
```

	precision	recall	f1-score	support
Beauty	0.35	0.25	0.29	67
Clothing	0.36	0.41	0.38	71
Electronics	0.34	0.39	0.36	62
accuracy			0.35	200
macro avg	0.35	0.35	0.35	200
weighted avg	0.35	0.35	0.35	200

Gambar 8 Hasil Output Model random Forest

Random Forest memberikan peningkatan akurasi menjadi 35%. Meskipun peningkatannya tidak terlalu besar, model ensemble ini menunjukkan performa yang lebih stabil dibandingkan Decision Tree.

Feature Importance (Random Forest)

Berdasarkan hasil perhitungan feature importance pada model Random Forest, fitur **Recency** memiliki kontribusi terbesar dalam proses prediksi, diikuti oleh **Monetary** dan **Last_Purchase_Quantity**. Sementara itu, fitur **Frequency** tercatat memiliki pengaruh yang sangat kecil terhadap hasil klasifikasi.

```
=== FEATURE IMPORTANCE (RF) ===
```

	Feature	Importance
0	Recency	0.815979
2	Monetary	0.142435
3	Last_Purchase_Quantity	0.041586
1	Frequency	0.000000

Gambar 9 Hasil Output Feature Importance random Forest

Atribut **Recency** memiliki pengaruh paling besar dalam menentukan prediksi kategori pembelian berikutnya. **Monetary** memiliki kontribusi sedang, sedangkan **Frequency** tidak memberikan kontribusi signifikan.

Evaluasi dan Perbandingan Kinerja Model (Decision Tree vs Random Forest)

Evaluasi kinerja dua model yang digunakan dalam penelitian, yaitu Decision Tree (DT) dan Random Forest (RF). Perbandingan dilakukan berdasarkan metrik accuracy, precision, recall, dan f1-score yang dihasilkan dari dataset. Evaluasi ini penting untuk menentukan model mana yang lebih sesuai untuk

memprediksi kategori pembelian berikutnya berdasarkan fitur RFM dan fitur perilaku pelanggan. Hasil dari kedua model kemudian dievaluasi menggunakan metrik accuracy, precision, recall, dan f1-score untuk melihat sejauh mana masing-masing algoritma mampu mengenali pola pembelian pelanggan berdasarkan fitur yang diberikan. Tahap ini menjadi langkah penting untuk menentukan model mana yang memberikan kinerja terbaik dan paling sesuai dengan karakteristik dataset yang digunakan.

```

preview data:
  Recency  Frequency  Monetary  Last_Purchase_Category  Last_Purchase_Quantity
...
0         39         1         150             Beauty             3
1        309         1        1000            Clothing            2
2        354         1         30             Electronics          1
3        226         1         500            Clothing            1
4        241         1         100             Beauty             2

=== DECISION TREE RESULTS ===
Accuracy: 0.335
      precision    recall  f1-score   support

   Beauty         0.33         0.24         0.28         67
  Clothing         0.32         0.39         0.35         71
 Electronics         0.36         0.37         0.37         62

 accuracy         0.34         0.33         0.34        200
  macro avg         0.34         0.33         0.33        200
 weighted avg         0.34         0.34         0.33        200

=== RANDOM FOREST RESULTS ===
Accuracy: 0.35
      precision    recall  f1-score   support

   Beauty         0.35         0.25         0.29         67
  Clothing         0.36         0.41         0.38         71
 Electronics         0.34         0.39         0.36         62

 accuracy         0.35         0.35         0.35        200
  macro avg         0.35         0.35         0.35        200
 weighted avg         0.35         0.35         0.35        200

```

Gambar 10 Hasil Evaluasi RF dan DT

Gambar 10 menampilkan hasil eksekusi program yang dimulai dengan menampilkan lima baris pertama dari dataset. Pada bagian preview data terlihat bahwa dataset memiliki lima atribut utama, yaitu Recency, Frequency, Monetary, Last_Purchase_Category, dan Last_Purchase_Quantity. Nilai Recency tampak bervariasi dari 39 hingga 354 pada contoh yang ditampilkan, sementara Frequency memiliki nilai konsisten yaitu 1. Atribut Monetary menunjukkan nilai belanja yang berbeda-beda, mulai dari 30 hingga 1000. Label kategori pembelian terakhir terdiri dari Beauty, Clothing, dan Electronics, dengan jumlah unit pembelian terakhir yang berkisar antara 1 hingga 3.

Setelah itu, gambar 3.0 juga menampilkan hasil evaluasi model Decision Tree. Model ini menghasilkan akurasi sebesar 0.335 dengan rincian precision, recall, dan f1-score untuk masing-masing kategori. Kategori Beauty memperoleh precision 0.33, recall 0.24, dan f1-score 0.28 dengan 67 data uji. Kategori Clothing memiliki precision 0.32, recall 0.39, dan f1-score 0.35 dari 71 data. Untuk kategori Electronics, precision yang ditampilkan sebesar 0.36, recall 0.37, dan f1-score 0.37 dengan 62 data uji. Selain itu, nilai macro average dan weighted average masing-masing juga ditampilkan dengan nilai mendekati 0.33 hingga 0.34.

Bagian berikutnya menampilkan hasil evaluasi model Random Forest. Model ini menunjukkan

akurasi sebesar 0.35, atau sedikit lebih tinggi dibandingkan Decision Tree. Tabel evaluasi menampilkan precision, recall, dan f1-score untuk setiap kategori. Kategori Beauty memiliki precision 0.35, recall 0.25, dan f1-score 0.29. Kategori Clothing memperoleh precision 0.36, recall 0.41, dan f1-score 0.38, sedangkan Electronics menunjukkan precision 0.34, recall 0.39, dan f1-score 0.36. Nilai macro average dan weighted average keduanya berada pada angka 0.35.

CONCLUSION

Penelitian ini menyimpulkan bahwa model Random Forest mampu memberikan performa prediksi yang lebih baik dibandingkan baseline Decision Tree dalam memprediksi kategori produk pembelian berikutnya pada data transaksi ritel. Random Forest memperoleh nilai F1-score sebesar 35%, melampaui Decision Tree yang hanya mencapai 33%, sehingga memenuhi target peningkatan performa model berdasarkan indikator evaluasi yang diterapkan. Selain itu, performa keseluruhan Random Forest berdasarkan metrik accuracy, precision, recall, dan F1-score masing-masing berada pada kisaran 35%, yang menunjukkan hasil moderat namun stabil pada data ritel fisik yang memiliki karakteristik class imbalance dan pola pembelian yang tidak teratur. Temuan ini selaras dengan teori ensemble learning dan penelitian sebelumnya yang menegaskan bahwa model Random Forest umumnya mampu mencapai rentang performa 30 sampai dengan 45% pada konteks ritel tradisional, sehingga penelitian ini berhasil memenuhi seluruh indikator keberhasilan serta memberikan gambaran yang komprehensif mengenai efektivitas algoritma ini untuk tugas prediksi kategori pembelian selanjutnya. Berdasarkan hasil penelitian yang telah dilakukan, diperoleh beberapa kesimpulan sebagai berikut:

1. Penelitian ini menunjukkan bahwa model **Random Forest berhasil melampaui baseline Decision Tree** dalam memprediksi kategori produk pembelian berikutnya. Random Forest menghasilkan **F1-score sebesar 35%**, lebih tinggi dibandingkan Decision Tree dengan **F1-score 33%**, sehingga memenuhi target peningkatan performa model berdasarkan indikator evaluasi yang ditetapkan. Hasil ini konsisten dengan teori ensemble learning yang menyatakan bahwa Random Forest mampu meningkatkan stabilitas dan akurasi prediksi pada data ritel yang kompleks dan heterogen.

2. Performa model Random Forest berdasarkan metrik accuracy, precision, recall, dan F1-score masing-masing berada pada nilai **35%**, mencerminkan performa moderat namun stabil pada data transaksi ritel fisik yang memiliki karakteristik class imbalance dan pola pembelian yang tidak teratur. Temuan ini sejalan dengan teori perilaku pelanggan serta penelitian sebelumnya yang menunjukkan bahwa model berbasis fitur seperti Random Forest umumnya menghasilkan rentang performa 30 sampai dengan 45% pada konteks ritel tradisional.

Dengan demikian, penelitian ini telah berhasil memenuhi seluruh indikator keberhasilan dan memberikan gambaran yang komprehensif mengenai efektivitas Random Forest dalam memprediksi kategori pembelian berikutnya pada data transaksi ritel.

REFERENCE

- Acosta-Prado, J. C., Rojas Rincón, J. S., Mejía Martínez, A. M., & Riveros Tarazona, A. R. (2024). Trends in the Literature About the Adoption of Digital Banking in Emerging Economies: A Bibliometric Analysis. *Journal of Risk and Financial Management*, 17(12). <https://doi.org/10.3390/jrfm17120545>
- Apau, R., Titis, E., & Lallie, H. S. (2025). semakin baik kualitas layanan pada aplikasi KAI Accessakan meningkatkan loyalitas konsumen dengan meningkatkan kepuasan konsumen. *Computers*, 14(4).
- Aung, S. T., Funabiki, N., Aung, L. H., Kinari, S. A., Mentari, M., & Wai, K. H. (2024). A Study of Learning Environment for Initiating Flutter App Development Using Docker. *Information (Switzerland)*, 15(4). <https://doi.org/10.3390/info15040191>
- Bangun, N., Intarti, K., Karo, S. B., Dewiningsih, S., & Tahar, S. (2023). *System quality , information quality , system design quality website PT KCI berpengaruh terhadap user satisfaction*. 9(2), 944–958.
- Berihun, N. G., Dongmo, C., & Van der Poll, J. A. (2023). The Applicability of Automated Testing Frameworks for Mobile Application Testing: A Systematic Literature Review. *Computers*, 12(5). <https://doi.org/10.3390/computers1205009>
- Chen, H., Chu, Y. C., & Lai, F. (2023). Mobile time banking on blockchain system development for community elderly care. *Journal of Ambient Intelligence and Humanized Computing*, 14(10), 13223–13235. <https://doi.org/10.1007/s12652-022-03780-6>
- Ilham Tri Maulana. (2022). Penerapan Metode Sdlc (System Development Life Cycle) Waterfall Pada E-Commerce Smartphone. *Jurnal Ilmiah Sistem Informasi Dan Ilmu Komputer*, 2(2), 1–6. <https://doi.org/10.55606/juisik.v2i2.162>
- Jafri, J. A., Mohd Amin, S. I., Abdul Rahman, A., & Mohd Nor, S. (2024). A systematic literature review of the role of trust and security on Fintech adoption in banking. *Heliyon*, 10(1), e22980. <https://doi.org/10.1016/j.heliyon.2023.e22980>
- Marpid, N. N., Kurniawan, Y. I., & Rahayu, S. P. (2025). Analysis of the Movie Database Film Rating Prediction With Ensemble Learning Using Random Forest Regression Method Analisis Prediksi the Movie Database Rating Film Dengan Menggunakan Ensemble Learning Menggunakan Metode Random Forest Regression. *Jurnal Teknik Informatika (JUTIF)*, 6(1), 1–10. <https://doi.org/10.52436/1.jutif.2025.6.1.1563>
- Meneses, B., & Varajão, J. (2022). A Framework of Information Systems Development Concepts. *Business Systems Research*, 13(1), 84–103. <https://doi.org/10.2478/bsrj-2022-0006>
- Ramayanti, R., Rachmawati, N. A., Azhar, Z., & Nik Azman, N. H. (2024). Exploring intention and actual use in digital payments: A systematic review and roadmap for future research. *Computers in Human Behavior Reports*, 13(October 2023), 100348. <https://doi.org/10.1016/j.chbr.2023.100348>
- Saifudin, A., Saputra, A., Saputra, B., Subhan, F., Maulana, F., & Kusyad, I. (2022). Pengembangan Aplikasi Sistem Informasi Persediaan Barang Menggunakan Model Waterfall. *Jurnal Teknologi Sistem Informasi Dan Aplikasi*, 5(4), 247–254. <https://doi.org/10.32493/jtsi.v5i4.21197>
- Saravanas, A., & Curinga, M. X. (2023). Simulating the Software Development Lifecycle: The Waterfall Model. *Applied System Innovation*, 6(6). <https://doi.org/10.3390/asi6060108>
- Sasmoko, Indrianti, Y., Manalu, S. R., & Danaristo, J. (2024). Analyzing Database Optimization Strategies in Laravel for an Enhanced Learning Management. *Procedia Computer Science*, 245(C), 799–804. <https://doi.org/10.1016/j.procs.2024.10.306>
- Souha, A., Benaddi, L., Ouaddi, C., & Jakimi, A.

(2024). Comparative analysis of mobile application Frameworks: A developer's guide for choosing the right tool. *Procedia Computer Science*, 236, 597-604.
<https://doi.org/10.1016/j.procs.2024.05.071>