

Klasifikasi Tingkat Penjualan Produk Menggunakan Algoritma *Decision Tree* Pada Multi Cabang ARR Cell

Husnul Hatimah^{1*}, Windarsyah², Ayu Ahadi Ningrum³

^{1,2,3}S1 Informatika, Universitas Muhammadiyah Banjarmasin, Barito Kuala, Indonesia

Email: ¹husnul_hatimah_2255201110008@umbjm.ac.id, ²windarsyah@umbjm.ac.id, ³ayuahadi@umbjm.ac.id

Email Penulis Korespondensi: ¹husnul_hatimah_2255201110008@umbjm.ac.id

Info Artikel	Abstrak
Kata Kunci: <i>Decision Tree</i> Klasifikasi Ritel Pelabelan Data Transaksi Multi Cabang	Toko ARR Cell merupakan usaha ritel telekomunikasi dengan volume transaksi tinggi yang menyulitkan identifikasi produk laris secara manual. Penelitian ini bertujuan membangun model klasifikasi tingkat penjualan produk menggunakan algoritma <i>Decision Tree</i> pada 187.877 data transaksi dari tujuh cabang periode Juli 2025 hingga Maret 2026. Karena dataset belum memiliki label, pelabelan dilakukan melalui metode <i>scoring</i> berbasis frekuensi transaksi dan total unit terjual, yang kemudian dikelompokkan menjadi empat kelas menggunakan metode kuartil. Model klasifikasi dibangun menggunakan algoritma <i>Decision Tree</i> dengan tujuh fitur prediktor transaksi. Hasil penelitian menunjukkan bahwa model mampu mengklasifikasikan tingkat penjualan produk dengan akurasi <i>testing</i> sebesar 74,32%, <i>precision</i> 74,44%, <i>recall</i> 74,32%, dan <i>F1-score</i> 73,92%. Selisih akurasi <i>training</i> dan <i>testing</i> yang kecil, yaitu 2,72%, menunjukkan bahwa model bersifat stabil, konsisten, dan tidak mengalami overfitting dalam memprediksi tingkat penjualan ritel pada multi cabang.
Keywords: Decision Tree Classification Retail Data Labeling Multi Branch Transactions	Abstract ARR Cell is a telecommunications retail business with a high transaction volume, making manual identification of best-selling products difficult. This study aims to build a product sales level classification model using the Decision Tree algorithm on 187,877 transaction data from seven branches for the period of July 2025 to March 2026. Since the dataset was unlabeled, data labeling was performed through a scoring method based on transaction frequency and total units sold, which were then grouped into four classes using the quartile method. The classification model was developed using the Decision Tree algorithm with seven transaction predictor features. The results showed that the model was able to classify product sales levels with a testing accuracy of 74.32%, precision of 74.44%, recall of 74.32%, and an F1-score of 73.92%. The small gap between training and testing accuracy, which is 2.72%, demonstrates that the model is stable, consistent, and does not experience overfitting in predicting retail sales levels across multi branch locations.

JuKSIT is licensed under a Creative Commons Attribution-Share Alike 4.0 International License



1. PENDAHULUAN

Kemajuan pesat dalam teknologi informasi telah memicu pergeseran digital di berbagai lini bisnis, termasuk sektor perdagangan eceran. Implementasi sistem pembayaran terkomputerisasi menghasilkan penyimpanan data penjualan secara otomatis dalam volume yang signifikan setiap hari. Informasi ini tidak hanya berfungsi sebagai catatan transaksi, tetapi juga dapat menjadi sumber wawasan krusial untuk menunjang proses penetapan strategi bisnis yang lebih efisien [1]. Akan tetapi, banyak entitas bisnis ritel masih menghadapi tantangan dalam mengubah data transaksi menjadi informasi yang berharga, mengingat proses analisis yang saat ini masih dilakukan secara manual dan memakan waktu. Situasi ini menggarisbawahi urgensi penerapan metode data mining untuk secara otomatis mengidentifikasi pola dan pengetahuan tersembunyi dari data transaksi masa lalu [2].

ARR Cell adalah sebuah entitas ritel yang fokus pada distribusi produk telekomunikasi dan barang kebutuhan sehari-hari. Portofolio produknya mencakup pulsa, paket data, voucher internet, dompet elektronik, token listrik, rokok, aksesoris ponsel, dan layanan isi ulang untuk permainan. Saat ini, ARR Cell mengoperasikan tujuh cabang yang berlokasi strategis di Banjarmasin, Kalimantan Selatan. Operasional harian yang melibatkan banyak transaksi menghasilkan volume data yang signifikan dan bervariasi. Analisis data transaksi dari Juli 2025 hingga Maret 2026 menunjukkan realisasi sejumlah 187.929 transaksi yang melibatkan 845 item produk berbeda, diklasifikasikan ke dalam 16 kategori.

Volume transaksi yang tinggi ini menghadirkan tantangan bagi manajemen dalam melakukan identifikasi produk berkinerja penjualan tinggi dan rendah secara manual. Konsekuensinya, efektivitas dalam pengambilan keputusan terkait manajemen persediaan, penetapan prioritas produk, dan pengembangan strategi promosi menjadi terbatas [3].

Salah satu pendekatan yang dapat digunakan untuk mengatasi permasalahan tersebut adalah teknik klasifikasi pada *data mining*. Klasifikasi merupakan metode untuk mengelompokkan data ke dalam kelas tertentu berdasarkan karakteristik atribut yang dimiliki [4]. Dalam konteks penjualan ritel, klasifikasi dapat digunakan untuk menentukan tingkat penjualan suatu produk berdasarkan pola transaksi historis. Berbagai algoritma klasifikasi telah dikembangkan, salah satunya adalah algoritma *Decision Tree*. Algoritma ini banyak digunakan karena memiliki kemampuan interpretasi yang baik, mudah dipahami, serta mampu menangani data numerik maupun kategorikal secara bersamaan [5]. Selain itu, *Decision Tree* mampu menghasilkan aturan keputusan dalam bentuk struktur pohon sehingga memudahkan pengguna dalam memahami proses klasifikasi yang dihasilkan model [6].

Beberapa penelitian sebelumnya menunjukkan bahwa algoritma *Decision Tree* memiliki performa yang baik pada permasalahan klasifikasi penjualan. Penelitian oleh Melfia dkk. [7] menerapkan algoritma C4.5 untuk klasifikasi tingkat penjualan produk ritel dan memperoleh hasil akurasi yang cukup baik. Penelitian lain oleh Rhodiyah dan Rahmawati [8] menggunakan algoritma *Naive Bayes* untuk klasifikasi penjualan produk UMKM, namun model mengalami penurunan performa akibat distribusi kelas yang tidak seimbang. Sementara itu, penelitian Rozi dan Yana [9] membandingkan beberapa algoritma klasifikasi seperti *Decision Tree*, *Random Forest*, dan *K-Nearest Neighbor* pada data transaksi ritel dan menyimpulkan bahwa *Decision Tree* memiliki interpretabilitas yang lebih baik dibandingkan algoritma lainnya. Penelitian lain yang dilakukan oleh Laurent dkk. [10] menunjukkan bahwa optimasi *hyperparameter* menggunakan *GridSearchCV* dapat meningkatkan performa model *Decision Tree* secara signifikan. Pada penelitian internasional, Muchsin dkk. [11] membuktikan bahwa algoritma *Decision Tree* berbasis Information Gain mampu menghasilkan performa klasifikasi yang baik pada data transaksi ritel multi-kategori. Selain itu, Widodo dkk. [12] menyatakan bahwa *Stratified Cross Validation* memberikan estimasi performa model yang lebih reliabel pada dataset dengan distribusi kelas yang beragam. Meskipun berbagai penelitian tersebut telah memberikan kontribusi penting dalam bidang klasifikasi penjualan, masih terdapat beberapa kesenjangan penelitian (*research gap*) yang perlu diperhatikan. Sebagian besar penelitian sebelumnya masih menggunakan dataset yang telah memiliki label bawaan. Padahal, pada kasus nyata seperti ARR Cell, label tingkat penjualan belum tersedia secara instan sehingga perlu dibentuk secara mandiri dari riwayat data. Di samping itu, penelitian terdahulu juga masih jarang membahas potensi terjadinya data *leakage* pada proses pembentukan label otomatis, yang berisiko memicu hasil evaluasi model menjadi terlalu optimis. Keterbatasan lain terlihat dari minimnya studi yang mengombinasikan optimasi *hyperparameter* menggunakan *GridSearchCV* dengan evaluasi berlapis menggunakan *10-fold Stratified Cross Validation* pada dataset transaksi ritel multi-cabang berskala besar. Terakhir, validitas metodologi pada beberapa riset terdahulu belum diverifikasi melalui uji independensi kuantitatif antara proses pembentukan label dengan fitur yang diikuti ke dalam model klasifikasi.


Untuk menjembatani celah riset tersebut, penelitian ini mengusulkan pendekatan klasifikasi tingkat penjualan produk menggunakan algoritma *Decision Tree* pada data transaksi ARR Cell melalui metodologi yang lebih ketat. Skema dimulai dengan pembentukan label tingkat penjualan secara otomatis memanfaatkan metode *scoring* berbasis frekuensi transaksi dan total unit terjual, yang kemudian dikelompokkan secara objektif ke dalam empat kelas menggunakan metode kuartil, yaitu Sangat Laku, Laku, Cukup Laku, dan Kurang Laku. Tahap berikutnya diperkuat dengan penerapan proses *feature engineering* yang menyertakan variabel segmen harga serta segmen waktu guna mempertajam sensitivitas model dalam mengenali fluktuasi pola transaksi. Sebelum dilakukan optimasi, algoritma klasifikasi sejenis seperti *Random Forest*, *AdaBoost*, *K-Nearest Neighbor (KNN)*, dan *Naive Bayes* menunjukkan tingkat akurasi yang lebih rendah dalam mengenali karakteristik data transaksi ini. Selanjutnya, guna mendapatkan parameter model yang optimal, diterapkan metode pengujian terstruktur menggunakan *GridSearchCV* yang dipadukan dengan *10-fold Stratified Cross Validation* demi menjamin kestabilan dan keandalan akurasi pada data berskala besar.

Tujuan penelitian ini adalah membangun model klasifikasi tingkat penjualan produk menggunakan algoritma *Decision Tree* pada data transaksi tujuh cabang ARR Cell periode Juli 2025 hingga Maret 2026. Selain itu, penelitian ini bertujuan mengembangkan metode pembentukan label otomatis yang objektif dan menganalisis hasil klasifikasi sebagai dasar pendukung pengambilan keputusan bisnis terkait pengelolaan stok, prioritas produk, dan strategi pemasaran berbasis data. Dengan adanya penelitian ini, diharapkan proses identifikasi produk laris pada ARR Cell dapat dilakukan secara lebih cepat, konsisten, dan akurat.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan klasifikasi data menggunakan algoritma *Decision Tree* untuk mengklasifikasikan tingkat penjualan produk pada Multi cabang ARR Cell. Tahapan penelitian disusun secara sistematis

mulai dari pengumpulan data, *Preprocessing* Data, *feature Engineering*, pemodelan, hingga evaluasi model. Kerangka alur penelitian [13] ditunjukkan pada Gambar 1.



Gambar 1. Alur tahapan *Decision Tree*

2.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data transaksi penjualan selama periode Juli 2025 hingga Maret 2026 dari 7 cabang toko ARR Cell yang berlokasi di Banjarmasin, yaitu ARR Cell Zamzam, ARR Cell Sutoyo, ARR Cell Kampung Melayu, ARR Cell Masjid Jami, ARR Cell Malkontemon, ARR Cell Sungai Andai, dan ARR Cell HKS. Data tersebut diperoleh langsung dari pemilik ARR Cell dalam format *spreadsheet* Microsoft Excel .xlsx dengan total 187.929 baris dan 7 kolom. Atribut data yang digunakan meliputi informasi tanggal dan waktu yang bertipe *datetime*, informasi cabang, nama produk, dan kategori yang bertipe *string*, serta informasi jumlah penjualan dan total uang diterima yang bertipe *integer*.

2.2 Preprocessing Data

Tahap *Preprocessing* data bertujuan membersihkan dan menyeragamkan data sebelum digunakan dalam pemodelan [14]. Proses ini terdiri atas empat langkah berurutan [15], yaitu :

- Standardisasi nama kolom: seluruh nama kolom dikonversi menjadi huruf kecil dan spasi diganti dengan garis bawah untuk kemudahan pemrosesan.
- Parsing tanggal dan ekstraksi fitur temporal: kolom tanggal dikonversi ke format *datetime* dan diekstraksi menjadi fitur bulan, nama hari, dan jam transaksi.
- Pembersihan teks dan konsolidasi kategori: nilai kategori yang mengandung kesalahan penulisan (*typo*) diperbaiki dan dikategorikan ulang, menghasilkan 16 kategori produk yang bersih.
- Penghapusan data tidak valid: sebanyak 47 baris dengan nilai transaksi negatif (transaksi void/retur) dan 5 baris duplikat dihapus. Tidak ditemukan nilai kosong (*missing value*) pada kolom kunci.

Hasil akhir *preprocessing* menghasilkan 187.877 baris data bersih dari 187.929 data awal, dengan total data yang dihapus sebesar 52 baris (0,03%). Dataset bersih terdiri dari 845 produk unik yang tersebar di 7 cabang.

2.3 Feature Engineering

Feature Engineering dilakukan untuk menghasilkan representasi data yang lebih informatif bagi model [16]. Fitur-fitur baru yang dibentuk antara lain:

- Segmen harga (segmen_harga): nilai nominal transaksi dikategorikan ke dalam lima tingkatan harga menggunakan fungsi pemetaan bertingkat: (1) $\leq$ Rp10.000, (2) Rp10.001–Rp25.000, (3) Rp25.001–Rp50.000, (4) Rp50.001–Rp100.000, dan (5) $>$ Rp100.000.
- Segmen waktu (segmen_waktu): jam transaksi dibagi ke dalam enam periode: (1) dini hari 00.00–05.59, (2) pagi 06.00–11.59, (3) siang 12.00–14.59, (4) sore 15.00–17.59, (5) malam 18.00–20.59, dan (6) malam larut 21.00–23.59

Selain itu, variabel kategorikal CABANG dan KATEGORI dikonversi ke representasi numerik menggunakan LabelEncoder dari scikit-learn, menghasilkan fitur cabang_enc (0–6) dan kategori_enc (0–15). Total terdapat tujuh fitur input yang digunakan sebagai variabel prediktor dalam model, yaitu: total_uang_diterima, segmen_harga, kategori_enc, cabang_enc, bulan, nama_hari, dan segmen_waktu.

2.4 Konstruksi Label Kelas Target

Label kelas target (tingkat_laku) dibangun berdasarkan skor popularitas produk (skor_laku) yang dihitung per produk menggunakan kombinasi frekuensi kemunculan dan total unit terjual. Formula skor dinyatakan pada Persamaan (1).

$$skor_{laku} = 0.6 \times norm_{frekuensi} + 0.4 \times norm_{unit} \quad (1)$$

Pada Persamaan (1) $norm_{frekuensi}$ adalah normalisasi min-max frekuensi kemunculan produk dan $norm_{unit}$ adalah normalisasi min-max total unit terjual. Skor ini sengaja tidak melibatkan variabel harga ($total_uang_diterima$) agar tidak terjadi kebocoran data (*data leakage*), mengingat $total_uang_diterima$ sekaligus digunakan sebagai fitur input model.

Pembagian kelas dilakukan menggunakan metode kuartil (Q1, Q2, Q3) terhadap distribusi skor_laku, menghasilkan empat kelas: SANGAT LAKU ($\geq Q3$), LAKU (Q2–Q3), CUKUP LAKU (Q1–Q2), dan KURANG LAKU ($< Q1$). Metode kuartil dipilih karena menghasilkan distribusi kelas yang proporsional tanpa memerlukan asumsi distribusi normal.

2.5 Pembagian Data dan Pemodelan *Decision Tree*

Dataset sebanyak 187.877 baris dibagi menggunakan metode *stratified train-test split* dengan rasio 80:20, sebagaimana ditunjukkan pada Tabel 1. Stratifikasi berdasarkan variabel label kelas memastikan proporsi setiap kelas terjaga merata pada kedua subset.

Tabel 1. Pembagian Dataset *Training* dan *Testing*

Subset Data	Jumlah Baris	Proporsi (%)	Metode Split
Data <i>Training</i>	150.301	80%	<i>Stratified</i>
Data <i>Testing</i>	37.576	20%	<i>Stratified</i>
Total	187.877	100%	—

Model yang digunakan adalah *Decision Tree Classifier* dari *scikit-learn* dengan kriteria pemisahan simpul menggunakan entropi (*Information Gain*) sebagaimana Persamaan (2).

$$H(S) = - \sum p_i \times \log_2(p_i) \quad (2)$$

Pada Persamaan (2) $H(S)$ adalah nilai entropi pada simpul S dan p_i adalah proporsi data dari kelas ke- i . Berdasarkan entropi tersebut, pemilihan atribut terbaik di setiap simpul dilakukan dengan menghitung *Information Gain* (IG) menggunakan Persamaan (3).

$$IG(S, A) = H(S) - \sum_v \left(\frac{|S_v|}{|S|} \right) \times H(S_v) \quad (3)$$

Pada Persamaan (3) $IG(S, A)$ adalah *information gain* atribut A pada himpunan S , dan S_v adalah subset data untuk setiap nilai v dari atribut A . Atribut dengan nilai IG tertinggi dipilih sebagai simpul pemisah pada setiap level pohon.

2.6 Pemodelan Klasifikasi *Decision Tree*

Proses pemodelan pada penelitian ini menggunakan pendekatan klasifikasi dengan algoritma *Decision Tree* untuk mengklasifikasikan tingkat penjualan produk pada tujuh cabang ARR Cell ke dalam empat kelas target, yaitu SANGAT LAKU, LAKU, CUKUP LAKU, dan KURANG LAKU. Algoritma *Decision Tree* bekerja dengan membentuk struktur pohon keputusan berdasarkan nilai *Information Gain*, sehingga setiap simpul menghasilkan aturan pemisahan (*splitting rules*) yang mampu membedakan data ke dalam kelas target secara bertahap hingga diperoleh hasil klasifikasi akhir. Model ini dibangun menggunakan 187.877 data transaksi yang dianalisis melalui tujuh fitur prediktor, meliputi $total_uang_diterima$, $segmen_harga$, $kategori_enc$, $cabang_enc$, $bulan$, $nama_hari$, dan $segmen_waktu$. Melalui pendekatan klasifikasi tersebut, model yang dihasilkan diharapkan mampu mengklasifikasikan tingkat penjualan produk pada setiap cabang secara akurat guna mendukung pengambilan keputusan strategis.

2.7 Evaluasi Model

Evaluasi kinerja model dilakukan menggunakan empat metrik standar klasifikasi multikelas: akurasi, presisi, *recall*, dan *F1-Score* [17]. Seluruh metrik dihitung dalam skema *weighted average* untuk mengakomodasi jumlah sampel

per kelas yang berbeda. Selain itu, dilakukan pengujian stabilitas menggunakan *10-Fold Stratified Cross-Validation* pada keseluruhan dataset [18].

Akurasi dihitung menggunakan Persamaan (4):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

Presisi dihitung menggunakan Persamaan (5):

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

Recall dihitung menggunakan Persamaan (6):

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

F1-Score dihitung menggunakan Persamaan (7):

$$F1-Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (7)$$

di mana TP (*True Positive*) adalah prediksi benar untuk kelas positif, TN (*True Negative*) adalah prediksi benar untuk kelas negatif, FP (*False Positive*) adalah prediksi positif yang salah, dan FN (*False Negative*) adalah prediksi negatif yang salah. Kondisi *overfitting* dinilai dengan membandingkan selisih akurasi data *training* dan *testing*, model dinyatakan tidak *overfitting* apabila selisih tersebut di bawah 5%.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dan pembahasan menggunakan algoritma *Decision Tree* mencakup *preprocessing* data dan konstruksi label kelas, pelatihan model, serta evaluasi kinerja dalam mengklasifikasikan produk ke dalam empat kelas yaitu SANGAT LAKU, LAKU, CUKUP LAKU, dan KURANG LAKU.

3.1 Hasil *Preprocessing* Data dan Konstruksi Label Kelas

Preprocessing terhadap 187.929 baris data transaksi ARR Cell periode Juli 2025–Maret 2026 menghasilkan 187.877 baris data bersih setelah penghapusan 47 transaksi negatif dan 5 duplikat (0,03%). Kategori produk dikonsolidasikan dari 25 menjadi 16 kategori terstandarisasi. Tidak ditemukan *missing value* pada seluruh kolom kunci. Label kelas target dibangun dari skor popularitas produk berdasarkan frekuensi kemunculan (bobot 0,6) dan total unit terjual (bobot 0,4), tanpa melibatkan variabel harga untuk menghindari data *leakage*. Verifikasi korelasi skor label terhadap total uang diterima menghasilkan nilai -0,0033 (di bawah ambang 0,1), dinyatakan aman. Pembagian empat kelas menggunakan metode kuartil dan *stratified split* 80:20 disajikan pada Tabel 3.

Tabel 3. Distribusi Label Kelas dan Pembagian Data *Training-Testing*

Label Kelas	Threshold Skor	Total (%)	Training	Testing
SANGAT LAKU	$\geq Q3$ (0,3893)	48.197 (25,7%)	38.557	9.640
LAKU	$Q2 - Q3$	46.258 (24,6%)	37.006	9.252
CUKUP LAKU	$Q1 - Q2$	46.920 (25,0%)	37.536	9.384
KURANG LAKU	$< Q1$ (0,0802)	46.502 (24,8%)	37.202	9.300
Total	—	187.877 (100%)	150.301	37.576


Tabel 3 menunjukkan proporsi setiap kelas pada rentang 24,6%–25,7%, menghasilkan distribusi yang seimbang sehingga model tidak berpotensi bias terhadap kelas mayoritas.

3.2 Hasil Pelatihan Model dan Analisis Pohon Keputusan

Model *Decision Tree* dilatih menggunakan 150.301 data *training*, menghasilkan struktur pohon keputusan dengan kedalaman 25 level dan 3.720 simpul daun (*leaf nodes*). Struktur pohon tersebut merepresentasikan aturan klasifikasi yang terbentuk secara bertahap berdasarkan nilai *Information Gain* dari tujuh fitur prediktor untuk


membedakan empat kelas target tingkat penjualan, yaitu SANGAT LAKU, LAKU, CUKUP LAKU, dan KURANG LAKU. Visualisasi tiga level pertama pohon keputusan ditunjukkan pada Gambar 2. Simpul akar menggunakan fitur kategori_enc (ambang 10,5) sebagai pemisah utama, membagi transaksi ke kelompok kategori kode ≤ 10 (ACC, E-WALLET, GOPAY, KARTU PERDANA, dan lainnya) dan kode > 10 (PULSA, ROKOK, TOKEN LISTRIK, TOP UP GAME, VOUCHER). Pada level kedua, total_uang_diterima menjadi pemisah dominan (ambang Rp15.500 dan Rp22.500), mengonfirmasi nilai transaksi sebagai pembeda kritis tingkat laku. Fitur bulan muncul pada level ketiga, mengindikasikan pola musiman berperan setelah dua kriteria utama terpenuhi. Struktur ini bersifat interpretatif dan dapat dijelaskan langsung kepada manajemen.

Visualisasi Pohon Keputusan (Decision Tree)
3 Level Pertama dari Total 25 Level



Gambar 2. Visualisasi Pohon Keputusan *Decision Tree* (3 Level Pertama)

Kontribusi setiap fitur terhadap keputusan model berdasarkan *Gini Importance Score* disajikan pada Gambar 3.



Gambar 3. Grafik *Feature Importance Model Decision Tree*

Gambar 3 menunjukkan distribusi kontribusi setiap fitur terhadap keputusan model berdasarkan *Gini Importance Score*. Secara keseluruhan, ketujuh fitur dapat dikelompokkan ke dalam tiga tingkatan kontribusi. Pertama, fitur nilai transaksi (total_uang_diterima) mendominasi secara signifikan dengan kontribusi 67,66%, mencerminkan bahwa nominal transaksi merupakan pembeda utama antarkelas penjualan — produk digital seperti voucher data dan e-wallet (Rp9.000–Rp50.000) memiliki frekuensi transaksi jauh lebih tinggi dibanding produk lain. Kedua, fitur karakteristik produk dan waktu periodik yaitu kategori_enc (16,84%) dan bulan (7,72%) memberikan kontribusi menengah, mengindikasikan bahwa jenis produk dan pola musiman turut memengaruhi tingkat kelakuan secara bermakna. Ketiga, fitur lokasi, segmentasi harga, dan waktu harian (cabang_enc 4,18%, segmen_harga 1,34%, nama_hari 1,17%, segmen_waktu 1,09%) memberikan kontribusi yang relatif kecil, mengindikasikan perilaku pembelian yang cukup konsisten lintas cabang dan sepanjang hari. Secara ringkas, nilai transaksi dan jenis produk adalah dua faktor dominan yang menentukan tingkat penjualan, sementara faktor waktu dan lokasi bersifat komplementer dalam keputusan model.

3.3 Hasil Evaluasi Kinerja Model *Decision Tree*

Evaluasi menggunakan akurasi, presisi, *recall*, *F1-Score* (weighted), dan *10-Fold Stratified Cross-Validation* disajikan pada Tabel 4.

Tabel 4. Ringkasan Hasil Evaluasi Kinerja Model *Decision Tree*


Metrik Evaluasi	Training (%)	Testing (%)	Selisih (%)	Status
Akurasi	77,04	74,32	2,72	Baik
Presisi (<i>weighted</i>)	77,24	74,44	2,79	Baik
<i>Recall</i> (<i>weighted</i>)	77,04	74,32	2,72	Baik
<i>F1-Score</i> (<i>weighted</i>)	76,68	73,92	2,76	Baik
CV 10-Fold	74,19 ± 0,29	—	—	Stabil

Tabel 4 menunjukkan Model menghasilkan akurasi *testing* 74,32% dengan selisih 2,72% terhadap *training*, di bawah ambang *overfitting* 5%, sehingga model dinyatakan tidak *overfitting* [19]. Hasil *10-Fold Cross-Validation* menunjukkan rata-rata 74,19% ± 0,29%, mengkonfirmasi model sangat stabil. Rincian kinerja per kelas pada data *testing* disajikan pada Tabel 5.

Tabel 5. *Classification Report* per Kelas pada Data *Testing*

Kelas	<i>Precision</i> (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)	<i>Support</i>
SANGAT LAKU	75,71	86,63	80,80	9.640

LAKU	73,00	82,70	77,55	9.252
CUKUP LAKU	71,69	67,80	69,69	9.384
KURANG LAKU	77,35	59,81	67,45	9.300
Weighted Average	74,44	74,32	73,92	37.576



Gambar 4. Confusion Matrix Model Decision Tree pada Data Testing

Berdasarkan Tabel 5 kelas SANGAT LAKU memperoleh *F1-Score* tertinggi (80,80%) dengan *recall* 86,63%, menunjukkan model sangat handal mengenali produk terlaris. Kelas CUKUP LAKU dan KURANG LAKU memiliki *F1-Score* lebih rendah (69,69% dan 67,45%) karena kedua kelas berada di zona perbatasan kuartil sehingga karakteristiknya saling berdekatan.

Gambar 4 memvisualisasikan distribusi prediksi model secara menyeluruh dalam bentuk matriks 4×4. Nilai pada diagonal utama (hijau) merepresentasikan prediksi yang benar (*True Positive* per kelas), sedangkan nilai di luar diagonal merepresentasikan kesalahan klasifikasi.

- Kelas SANGAT LAKU: dari 9.640 data aktual, sebanyak 8.351 (86,6%) diprediksi benar. Kesalahan terbesar adalah 530 data yang salah diprediksi sebagai KURANG LAKU, menunjukkan sebagian produk SANGAT LAKU memiliki skor yang berdekatan dengan kelas tersebut.
- Kelas LAKU: dari 9.252 data aktual, sebanyak 7.651 (82,7%) diprediksi benar. Sebanyak 844 data salah diprediksi sebagai CUKUP LAKU, mengindikasikan tumpang tindih karakteristik di kelas menengah atas.
- Kelas CUKUP LAKU: dari 9.384 data aktual, sebanyak 6.362 (67,8%) diprediksi benar. Kesalahan terbesar adalah 1.148 data yang diprediksi sebagai SANGAT LAKU dan 1.110 data sebagai LAKU, menunjukkan kesulitan membedakan kelas perbatasan atas.
- Kelas KURANG LAKU: dari 9.300 data aktual, sebanyak 5.562 (59,8%) diprediksi benar. Sebanyak 1.387 data salah diprediksi sebagai LAKU dan 1.242 data sebagai CUKUP LAKU. Ini merupakan kelas dengan *recall* terendah karena skor popularitasnya berdekatan dengan kelas CUKUP LAKU.

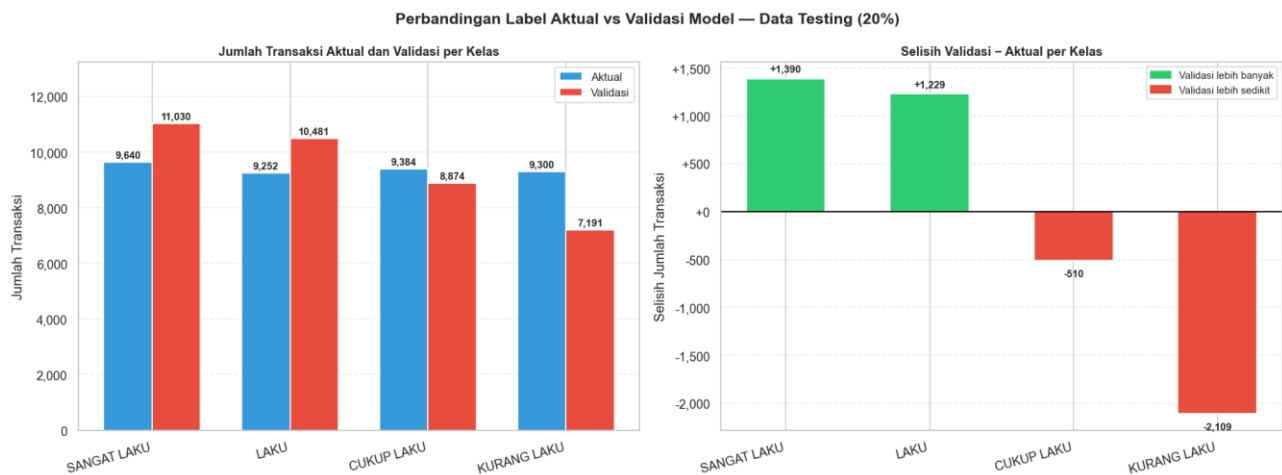
Secara keseluruhan, diagonal utama memperlihatkan bahwa model lebih akurat pada kelas ujung (SANGAT LAKU dan LAKU) dibandingkan kelas tengah (CUKUP LAKU dan KURANG LAKU). Pola ini konsisten dengan prinsip klasifikasi berbasis kuartil, di mana kelas-kelas yang berada di batas antar-kuartil memiliki jarak skor yang lebih sempit sehingga lebih sulit dipisahkan.

Hasil prediksi model mengidentifikasi tiga produk SANGAT LAKU teratas: V. AXIS 5 GB/3H (13.818 unit), DANA 50.000 (13.455 unit), dan DANA 100.000 (9.104 unit). Produk digital mendominasi seluruh 7 cabang, mencerminkan tingginya penetrasi layanan digital di Banjarmasin. Implikasi praktisnya meliputi:

- Manajemen stok:** produk SANGAT LAKU diprioritaskan dalam pengadaan untuk menghindari stockout pada bulan permintaan tinggi.
- Promosi tertarget:** variasi produk terlaris antar cabang dimanfaatkan untuk promosi spesifik per lokasi.

3. **Evaluasi produk:** produk KURANG LAKU dikaji untuk diputus atau diganti varian yang lebih sesuai preferensi pelanggan lokal.

Guna menguji keandalan model klasifikasi yang telah terbentuk, dilakukan tahapan validasi dengan membandingkan label hasil prediksi model terhadap label aktual pada data pengujian sebesar 20% (37.576 transaksi). Hasil perbandingan sebaran frekuensi kedua label tersebut divisualisasikan pada Gambar 5.



Gambar 5. Grafik Perbandingan Label Aktual vs Validasi Model

Berdasarkan visualisasi pada Gambar 5, distribusi hasil validasi model menunjukkan pola yang secara umum mengikuti distribusi data aktual pada setiap kelas. Pada kelas SANGAT LAKU, jumlah data aktual sebanyak 9.640 transaksi, sedangkan hasil validasi model sebanyak 11.030 transaksi sehingga terdapat selisih +1.390 transaksi. Pada kelas LAKU, jumlah data aktual sebanyak 9.252 transaksi dan hasil validasi model sebanyak 10.481 transaksi dengan selisih +1.229 transaksi. Sebaliknya, pada kelas CUKUP LAKU dan KURANG LAKU, model menghasilkan jumlah validasi yang lebih rendah dibandingkan data aktual. Kelas CUKUP LAKU memiliki 9.384 data aktual dan 8.874 hasil validasi (selisih -510), sedangkan kelas KURANG LAKU memiliki 9.300 data aktual dan 7.191 hasil validasi (selisih -2.109). Perbedaan tersebut menunjukkan bahwa model cenderung lebih sering mengklasifikasikan data ke kategori SANGAT LAKU dan LAKU, sementara jumlah hasil validasi pada kategori CUKUP LAKU dan KURANG LAKU relatif lebih sedikit. Temuan ini konsisten dengan hasil *confusion matrix* yang menunjukkan bahwa kelas KURANG LAKU memiliki nilai recall terendah sebesar 59,8%, sehingga lebih banyak data pada kelas tersebut yang diklasifikasikan ke kelas lain. Meskipun demikian, model tetap menunjukkan kinerja yang cukup baik dengan nilai akurasi sebesar 74,32% serta rata-rata 10-fold *Stratified Cross Validation* sebesar $74,19\% \pm 0,29\%$, sehingga layak digunakan sebagai pendukung klasifikasi tingkat penjualan produk pada ARR Cell.

4. KESIMPULAN

Penelitian ini berhasil membangun model klasifikasi tingkat penjualan produk pada Toko ARR Cell menggunakan algoritma Decision Tree berdasarkan data transaksi periode Juli 2025 hingga Maret 2026. Proses pelabelan dilakukan secara otomatis menggunakan metode scoring berbasis frekuensi transaksi dan total unit terjual, kemudian dikelompokkan menjadi empat kategori tingkat penjualan menggunakan metode kuartil, yaitu SANGAT LAKU, LAKU, CUKUP LAKU, dan KURANG LAKU. Hasil pengujian menunjukkan bahwa model mampu mengklasifikasikan tingkat penjualan produk dengan akurasi *testing* sebesar 74,32%, *precision* 74,44%, *recall* 74,32%, dan *F1-score* 73,92%, sehingga tujuan penelitian untuk membangun model klasifikasi tingkat penjualan produk telah tercapai. Selain itu, evaluasi menggunakan 10-fold *Stratified Cross Validation* menghasilkan rata-rata akurasi sebesar 74,19% dengan standar deviasi 0,29%, yang menunjukkan konsistensi performa model pada berbagai pembagian data. Selisih akurasi *training* dan *testing* sebesar 2,72% juga mengindikasikan bahwa model tidak menunjukkan gejala *overfitting* yang signifikan. Analisis *feature importance* menunjukkan bahwa fitur *total_uang_diterima* merupakan faktor yang paling berpengaruh dalam proses klasifikasi dengan kontribusi sebesar 67,66%, sehingga memberikan gambaran mengenai pentingnya nilai transaksi dalam menentukan tingkat penjualan produk. Hasil penelitian ini menunjukkan bahwa algoritma *Decision Tree* dapat dimanfaatkan sebagai pendekatan klasifikasi untuk membantu identifikasi tingkat penjualan produk berdasarkan

data transaksi, sehingga dapat mendukung pengambilan keputusan dalam pengelolaan stok, penentuan prioritas produk, dan penyusunan strategi promosi pada jaringan toko ARR Cell. Dengan demikian, penerapan algoritma *Decision Tree* memberikan alternatif yang dapat digunakan untuk mendukung pengelolaan penjualan ritel multi cabang berbasis data. Penelitian selanjutnya dapat membandingkan performa algoritma *Decision Tree* dengan metode *ensemble learning* seperti *XGBoost* guna memperoleh peningkatan kinerja model dalam mengklasifikasikan tingkat penjualan produk.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada pemilik ARR Cell yang telah memberikan izin, dukungan, serta akses terhadap data yang digunakan dalam penelitian ini. Penulis juga menyampaikan terima kasih kepada dosen pembimbing atas arahan, masukan dan bimbingan selama pelaksanaan penelitian dan penyusunan artikel ini. Ucapan terima kasih juga penulis sampaikan kepada orang tua dan keluarga atas doa, dukungan, motivasi, serta semangat yang diberikan selama proses penelitian. Selain itu, penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan bantuan dan kontribusi, baik secara langsung maupun tidak langsung, sehingga penelitian ini dapat diselesaikan dengan baik.

REFERENCES

- [1] W. G. S. Parwita, N. L. W. S. R. Ginantra, I. M. D. P. Asana, dan I. G. L. A. S. Dharma, "Retail Data Visualization in Business Intelligence System for Ayu Nadi Group," dalam *Proceedings of the 4th International Conference on Vocational Education and Technology, IConVET 2021, 27 November 2021, Singaraja, Bali, Indonesia*, Singaraja, Indonesia: EAI, 2022. doi: 10.4108/eai.27-11-2021.2315530.
- [2] K. Nisa, "Penerapan Data Mining Terhadap Data Transaksi Sebagai Pendukung Informasi Strategi Penjualan Menggunakan Algoritma Apriori," *Jurnal Teknik Informatika UNIKA Santo Thomas*, hlm. 306–315, Des 2021, doi: 10.54367/jtiust.v6i2.1454.
- [3] M. Noval dan F. D. Marleny, "Implementasi Algoritma K-Means Untuk Analisis Pola Penjualan Pada Toko Monisa," vol. 6, no. 3, 2025.
- [4] D. Pangestu, N. N. Zakiyyah, N. Fauziah, Z. Rahayu, dan I. Heidiani, "Literature Review: Perbandingan Metode Klasifikasi Dalam Data Mining," vol. 1, no. 11, 2024.
- [5] F. Rozi dan A. A. Yana, "Pemanfaatan Algoritma Decision Tree untuk Mengklasifikasikan Perilaku Konsumennya dalam Platform E-Commerce Berbasis Data Transaksi," 2026.
- [6] E. Ermawati, Bambang Irawan, dan Nur Ariesanto Ramdhan, "Klasifikasi Persediaan Obat Menggunakan Algoritma Decision Tree di Puskesmas Brebes," *Juritek*, vol. 5, no. 2, hlm. 415–432, Jul 2025, doi: 10.51903/juritek.v5i2.5061.
- [7] M. A. Melfia, K. A. Ramadhini, M. A. Maulana, A. L. Dasiva, A. A. Briantoro, dan B. O. Lubis, "PENERAPAN DATA MINING UNTUK KLASIFIKASI DATA PENJUALAN SEMBAKO TERLARIS DENGAN ALGORITMA C4.5," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 3, hlm. 4616–4621, Mei 2025, doi: 10.36040/jati.v9i3.13450.
- [8] R. Rhodiyah dan D. Rahmawati, "Penerapan Metode Naive Bayes untuk Klasifikasi Produk Kurang Diminati Berdasarkan Data Penjualan di Toko Laris Eksis," *Jurnal Indonesia : Manajemen Informatika dan Komunikasi*, vol. 6, no. 3, hlm. 1950–1957, Sep 2025, doi: 10.63447/jimik.v6i3.1601.
- [9] F. Rozi dan A. A. Yana, "Pemanfaatan Algoritma Decision Tree untuk Mengklasifikasikan Perilaku Konsumennya dalam Platform E-Commerce Berbasis Data Transaksi," 2026.
- [10] F. Laurent, S. Winarno, dan I. N. Dewi, "Optimasi Algoritma Decision Tree Menggunakan GridSearchCV untuk Klasifikasi Tipe Obesitas," vol. 7, no. 3, 2025.
- [11] A. G. K. Muchsin, N. Rahaningsih, I. Ali, D. Sudrajat, dan S. Anwar, "Application of Decision Tree Algorithms to Classify the Sales Results of Kangen Kripik Sme Products".
- [12] S. Widodo, H. Brawijaya, dan S. Samudi, "Stratified K-fold cross validation optimization on machine learning for prediction," *Sinkron : jurnal dan penelitian teknik informatika*, vol. 6, no. 4, hlm. 2407–2414, Okt 2022, doi: 10.33395/sinkron.v7i4.11792.
- [13] F. Laurent, S. Winarno, dan I. N. Dewi, "Optimasi Algoritma Decision Tree Menggunakan GridSearchCV untuk Klasifikasi Tipe Obesitas," vol. 7, no. 3, 2025.
- [14] "Apa itu Preprocessing Data, Manfaat dan Tahapannya." Diakses: 23 Juni 2026. [Daring]. Tersedia pada: <https://www.cakrawala.ac.id/berita/apa-itu-preprocessing-data>
- [15] R. Hans, "Mengapa Data Preprocessing Penting dalam Machine Learning?" Diakses: 8 Juni 2026. [Daring]. Tersedia pada: <https://dqlab.id/mengapa-data-preprocessing-penting-dalam-machine-learning>
- [16] "Feature Engineering: Definisi, Teknik, dan Praktik Baiknya." Diakses: 23 Juni 2026. [Daring]. Tersedia pada: <https://digitalskola.com/blog/data-engineer/feature-engineering>

-
- [17] Rina, “Memahami Confusion Matrix: Accuracy, Precision, Recall, Specificity, dan F1-Score untuk Evaluasi...,” Medium. Diakses: 3 Juni 2026. [Daring]. Tersedia pada: <https://esairina.medium.com/memahami-confusion-matrix-accuracy-precision-recall-specificity-dan-f1-score-610d4f0db7cf>
- [18] s-polly, “Evaluate AutoML experiment results - Azure Machine Learning.” Diakses: 23 Juni 2026. [Daring]. Tersedia pada: <https://learn.microsoft.com/en-us/azure/machine-learning/how-to-understand-automated-ml?view=azureml-api-2>
- [19] F. Anjany, N. M. Annisa’, dan M. A. Yaqin, “Manajemen Proyek ERP Berbasis Nilai: Prediksi Manfaat Menggunakan XGBoost,” no. 3, 2026.