

ANALISIS PERFORMA PENJUALAN ELEKTRONIK MENGUNAKAN METODE RFM DAN *NEURAL NETWORK* (STUDI KASUS PT. MAKMUR SUMBER REDJEKI)

Khanes Setiyo Aji^{1*}, Winarni², Achmad Hindasyah³

¹Program Studi Teknik Informatika S-2 Universitas Pamulang,²Badan Riset dan Inovasi Nasional,

³Program Studi Teknik Informatika S-2 Universitas Pamulang

khanessetiyoaji21@gmail.com¹, wina005@brin.go.id², ahindasyah@gmail.com³

Submitted November 24, 2025; Revised February 14, 2026; Accepted February 20, 2026

Abstrak

Perkembangan teknologi informasi dan meningkatnya persaingan bisnis menuntut perusahaan untuk mampu menganalisis data historis penjualan secara efektif guna memahami perilaku pelanggan dan meningkatkan strategi pemasaran. Penelitian ini bertujuan untuk menganalisis performa penjualan elektronik pada PT. Makmur Sumber Redjecki dengan mengombinasikan metode *Recency, Frequency, Monetary* (RFM) dan model *Neural Network*. Metode RFM digunakan untuk mengelompokkan pelanggan berdasarkan waktu terakhir transaksi, frekuensi pembelian, dan nilai transaksi, sedangkan *Neural Network* dimanfaatkan untuk mengklasifikasikan pelanggan ke dalam kategori loyal, potensial, dan berisiko churn secara lebih akurat. Data penelitian berupa transaksi penjualan pelanggan selama satu tahun yang diolah menggunakan pendekatan *supervised learning*. Tahapan analisis meliputi normalisasi data, segmentasi pelanggan dengan RFM, serta pelatihan model *Neural Network* menggunakan fitur-fitur RFM sebagai input. Hasil penelitian menunjukkan bahwa integrasi metode RFM dengan Resiko 38,5%, Loyal 30,8% dan Potensial 30,8% dan *Neural Network* meningkatkan akurasi 75% dalam mengidentifikasi pelanggan strategis serta memberikan wawasan penting bagi pengambilan keputusan pemasaran berbasis data.

Kata Kunci: RFM, *Neural Network*, Analisis Penjualan, Loyalitas Pelanggan, Pemasaran Berbasis Data

Abstract

The development of information technology and increasing business competition require companies to effectively analyze historical sales data to understand customer behavior and improve marketing strategies. This study aims to analyze the electronic sales performance of PT. Makmur Sumber Redjecki by combining the Recency, Frequency, Monetary (RFM) method and a Neural Network model. The RFM method is used to group customers based on the last transaction time, purchase frequency, and transaction value, while the Neural Network model is used to more accurately classify customers into loyal, potential, and at-risk churn categories. The research data consists of customer sales transactions over a one-year period, processed using a supervised learning approach. The analysis stages include data normalization, customer segmentation using RFM, and training a Neural Network model using RFM features as input. The results of the study show that the integration of the RFM method with Risk 38.5%, Loyal 30.8% and Potential 30.8% and Neural Network is able to increase the accuracy of 75% in identifying strategic customer groups and producing useful insights in supporting data-based marketing decision making.

Keywords: RFM, *Neural Network*, Sales Analysis, Customer Loyalty, Data-Driven Marketing

1. PENDAHULUAN

Dalam era digital dan persaingan bisnis yang semakin kompetitif, data telah menjadi aset strategis yang sangat berharga bagi perusahaan. Salah satu bentuk data yang paling melimpah dalam sektor ritel adalah

data historis penjualan, yang mencakup informasi penting mengenai perilaku pelanggan, seperti waktu pembelian, frekuensi transaksi, dan nilai transaksi. PT. Makmur Sumber Redjecki merupakan perusahaan yang bergerak di bidang ritel dan

telah memiliki sistem pencatatan penjualan yang cukup baik. Data histori penjualan selama ini hanya digunakan sebagai arsip laporan keuangan bulanan dan tahunan, dan belum dijadikan bahan analisis dalam merancang strategi pemasaran maupun pengambilan keputusan bisnis.

Tanpa adanya analisis yang mendalam terhadap data tersebut, perusahaan berisiko kehilangan peluang untuk memahami kebutuhan pelanggan, mengidentifikasi segmen pasar potensial, serta merancang strategi retensi pelanggan yang lebih efektif. Hal ini juga membuat perusahaan cenderung bersifat reaktif dibandingkan proaktif dalam menghadapi dinamika pasar.

Metode *Recency, Frequency, Monetary* (RFM) dapat digunakan untuk mengelompokkan pelanggan berdasarkan waktu terakhir transaksi, frekuensi pembelian, dan nilai transaksi. Sementara itu, Metode *Neural Network* dapat dimanfaatkan untuk memprediksi pola pembelian pelanggan secara lebih akurat berdasarkan variabel-variabel RFM tersebut. Penelitian oleh [1] menunjukkan bahwa metode RFM dapat meningkatkan efektivitas kampanye pemasaran melalui segmentasi pelanggan yang lebih tepat sasaran. Selanjutnya, penelitian oleh [2] membuktikan bahwa penerapan *Neural Network* pada industri ritel dapat menghasilkan prediksi penjualan dengan tingkat akurasi yang tinggi. Selanjutnya, penelitian oleh [3] dalam mengelompokkan tingkat peminatan produk, sehingga dapat membantu pengambilan keputusan dalam pengelolaan stok dan strategi pemasaran. Penelitian oleh [4] yang mengungkapkan bahwa integrasi antara RFM dan machine learning secara signifikan dapat meningkatkan kinerja penjualan di sektor elektronik. Sedangkan penelitian terbaru oleh [5] Menunjukkan bahwa pendekatan hybrid antara RFM dan Deep Learning memberikan insight yang lebih mendalam terhadap perilaku pelanggan dan tren pembelian. Selanjutnya, penelitian oleh [6]

menemukan bahwa optimasi *Neural Network* menggunakan grid search dan algoritma genetika mampu meningkatkan akurasi prediksi penjualan elektronik secara signifikan, sehingga menegaskan pentingnya *hyperparameter tuning* dalam meningkatkan kinerja model. selanjutnya penelitian oleh [7] menunjukkan hasil neural network mampu mendukung pengambilan keputusan dalam perencanaan penjualan, khususnya untuk membantu pengelolaan persediaan dan peningkatan efisiensi operasional e-commerce. Sedangkan penelitian oleh [8] menunjukkan bahwa integrasi metode RFM dengan NN dalam sistem prediksi penjualan real-time mampu meningkatkan responsivitas perusahaan terhadap dinamika pasar, pendekatan efektif dalam mengurangi ketidakpastian perencanaan penjualan serta mendukung peningkatan efisiensi operasional melalui pemanfaatan data e-commerce secara langsung.

Berdasarkan keseluruhan hasil analisis, penelitian menyimpulkan bahwa integrasi metode *Recency, Frequency, Monetary* (RFM) dan *Neural Network* mampu meningkatkan pemahaman terhadap perilaku pelanggan secara prediktif dan strategis. celah penelitian yang diangkat dalam studi yang terletak pada penerapan pendekatan integrative, mengingat penelitian sebelumnya umum menggunakan analisis RFM secara deskriptif atau Neural Network secara terpisah. Dengan memanfaatkan hasil segmentasi RFM sebagai input pada model Neural Network, penelitian ini tidak hanya menghasilkan segmentasi pelanggan berdasarkan perilaku historis, tetapi juga memungkinkan prediksi nilai pelanggan secara akurat. Penerapan metode ini pada studi kasus PT. Makmur Sumber Redjeki dalam konteks penjualan barang elektronik memberikan kontribusi empiris bagi pengembangan strategi pemasaran berbasis data.

Penelitian ini bertujuan menganalisis performa penjualan elektronik pada PT. Makmur Sumber

Redjeki dengan mengintegrasikan metode RFM dan *Neural Network*. Secara khusus, tujuan penelitian ini adalah menganalisis performa pelanggan berdasarkan data transaksi historis menggunakan metode RFM secara deskriptif, Mengklasifikasikan pelanggan ke dalam kategori loyal, potensial, dan berisiko *churn* dan memanfaatkan hasil RFM sebagai variabel input pada model *neural network* yang bersifat prediktif, serta Menyusun rekomendasi awal bagi manajemen dalam penentuan strategi pemasaran dan peningkatan penjualan berdasarkan hasil analisis RFM dan *Neural Network*.

Manfaat yang diharapkan dari penelitian ini adalah Mengembangkan pendekatan analisis data melalui integrasi metode RFM yang bersifat deskriptif dan *neural network* yang bersifat prediktif dalam evaluasi perilaku pelanggan, Mendukung upaya peningkatan *customer lifetime value (CLV)* serta daya saing perusahaan melalui pemahaman karakteristik pelanggan yang lebih akurat, dan memperkuat pengambilan keputusan strategis berbasis data (*data-driven decision marking*) dalam pengelolaan serta pengembangan strategi pemasaran perusahaan.

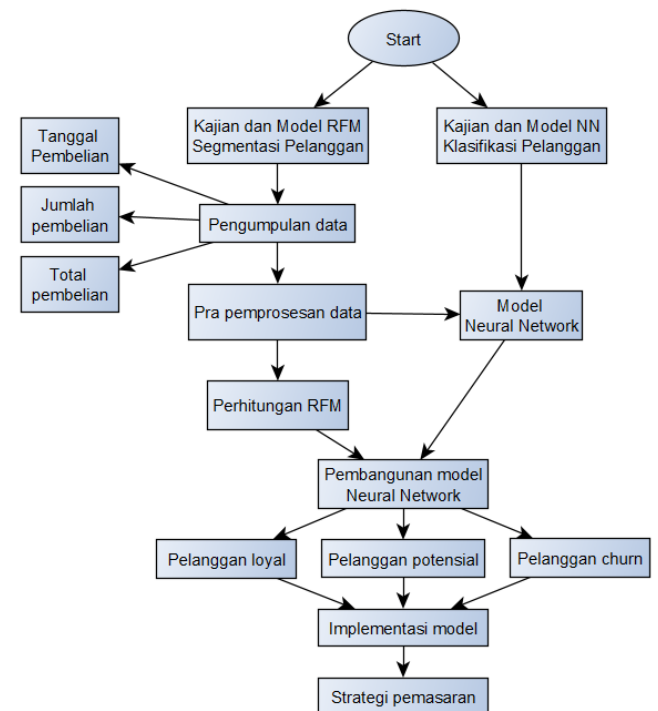
2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode studi kasus pada PT. Makmur Sumber Redjeki. Analisis dilakukan untuk mengidentifikasi pola pembelian pelanggan berdasarkan data historis dengan pendekatan prediktif dalam klasifikasi pelanggan guna mendukung pengambilan strategis yang berbasis data.

Data yang digunakan berupa data historis transaksi penjualan pelanggan selama satu tahun 2024, yang mencakup tanggal transaksi, jumlah transaksi, dan total nilai pembelian. Populasi penelitian meliputi seluruh data transaksi dan pelanggan yang tercatat dalam periode tersebut. Teknik pengambilan sampel dilakukan menggunakan *purposive sampling*, dengan kriteria pelanggan yang melakukan transaksi

berulang (*repeat order*). Berdasarkan karakteristik transaksi, pelanggan dikelompokkan ke dalam tiga kelas, yaitu pelanggan loyal, pelanggan potensial, dan pelanggan risiko (*churn*).

Pengumpulan data dilakukan dengan observasi, wawancara, dan studi kepustakaan. Observasi dilakukan secara langsung di gudang cabang tanggerang selatan untuk memahami proses pencatatan dan pengelolaan data penjualan. Wawancara dilakukan dengan manager sales untuk memperoleh informasi kontekstual terkait strategi penjualan dan karakteristik pelanggan. Studi kepustakaan dilakukan dengan menelaah buku, jurnal nasional dan internasional terakreditasi, serta publikasi ilmiah lain yang relevan sebagai landasan teoritis dan metodologis.



Gambar 1. Perancangan Penelitian

Tahapan pra-pemrosesan pada gambar 1 Perancangan penelitian yang meliputi pada pembersihan data dari nilai duplikat dan data kosong (*missing value*). Selanjutnya, data dinormalisasi menggunakan metode min-max scaling agar seluruh variabel berada

pada rentang nilai yang seragam, [0-1] sehingga dapat meningkatkan stabilitas dan kinerja model *Neural Network*.

Metode perhitungan *Recency*, *Frequency*, *Monetary* digunakan untuk mengevaluasi perilaku pelanggan secara deskriptif berdasarkan tiga dimensi utama, yaitu:

- *Recency* (R)
 $R_i = T_{cutoff} - T_{last_transaction}$ (1)
- *Frequency* (F)

$$F_i = \sum_{j=1}^{n_1} .$$

- *Monetary* (M)

$$M_1 = \sum_{j=1}^{n_i} amount_{ij}$$

- Normalisasi data (2)
Sebelum dimasukkan kedalam *Neural Network*, data RFM di normalisasi menggunakan Min-Max Scaling:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Skor RFM ini digunakan untuk membentuk segmentasi awal pelanggan dan menjadi representasi numerik perilaku pembelian historis.

Model *Neural Network* yang digunakan adalah tipe *Multilayer Perceptron* (MLP) dengan struktur sebagai berikut:

- Input layer: 3 neuron (R,F,m)
- Hidden layer: 1-2 lapisan tersembunyi (ReLU)
- Output layer : 3 neuron (dengan Softmax untuk klasifikasi multi-kelas)

Rumus fungsi aktivitas softmax digunakan output layer:

$$P(y = C | X) = \frac{e^{z_c}}{\sum_{k=1}^K e^{z_k}} \quad (3)$$

Model dilatih dengan fungsi loss categorial cross-entropy:

$$L = - \sum_{i=1}^n \sum_{c=1}^C Y_{ic} \log(Y_{ic})$$

Proses dilakukan secara iterative hingga model mencapai konvergensi yang optimal. Evaluasi performa model klasifikasi dilakukan berdasarkan metrik berikut, merujuk pada (Martinez et al., 2025).

- a. Akurasi (4)

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

- b. Presisi (5)

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

- c. Recall (6)

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

- d. F1 - SCORE (7)

$$F1 = 2 \frac{Precision \cdot Recall}{Precision + Recall}$$

- e. Confusion Matrix (8)

Digunakan untuk mengevaluasi akurasi klasifikasi perkelas pelanggan.

- f. ROC CURVE dan AUC (Area Under Curve). (9)

Untuk mengatur sentivitas dan spesifisitas model terhadap klasifikasi masing-masing kelas pelanggan.

3. HASIL DAN PEMBAHASAN

Hasil analisis segmentasi pelanggan menggunakan metode *Recency*, *Frequency*, *Monetary* (RFM) menunjukkan bahwa data histori transaksi PT. Makmur Sumber Redjeki dapat dikelompokkan secara objektif berdasarkan pola pembelian pelanggan. Perhitungan nilai *Recency*, *Frequency*, *Monetary* menghasilkan skor RFM yang merepresikan tingkat aktivitas dan nilai pelanggan bagi perusahaan. Berdasarkan tabel 1 Demografi Kategori (*Product Demographics*) memiliki karakteristik demografis yang beragam selama periode

pengamatan. Distribusi pelanggan pada setiap kategori menunjukkan adanya perbedaan latar belakang yang berpotensi memengaruhi pola transaksi, frekuensi pembelian, serta nilai transaksi yang dihasilkan. Dengan memahami karakteristik perusahaan dapat mengaitkan hasil segmentasi RFM dan Neural Network lebih komprehensif, sehingga strategi pemasaran yang lebih tepat sasaran.

Tabel 1 Demografi Kategori (*Product Demographics*)

No	Atribut	Penjelasan Atribut	Skala	Cara pengisian
1	Tahun model/rilis (elektronik)	Tahun resmi produk diperkenalkan ke pasar	Rasio	Angka bulan tahun (e.g., 2024)
2	Bahan baku utama (furnitur)	Material dominan yang membentuk produk.	Nominal kategori	Pilihan dari daftar (e.g., "kayu solid", "plywood", "plastik").
3	Fungsi spesifik (ATK)	Klasifikasi kegunaan produk.	Nominal kategori	Pilihan dari daftar (e.g., "Habis Pakai", "Pencatatan", "Pengarsipan", "Administrasi").
4	Masa garansi (elektronik)	Durasi jaminan resmi dari produsen.	Rasio	Durasi dalam bulan (e.g., 12 bulan, 24 bulan, "Tidak Ada").
5	Gaya desain (furnitur)	Klasifikasi estetika produk.	Nominal kategori	Pilihan dari daftar (e.g., "Minimalis", "Klasik", "Industrial", "Kontemporer").

Pada Tabel 1 Demografi Kategori (*Product Demographics*) Menggunakan metode *Recency, Frequency, Monetary* (RFM) dan *Neural Network* sebagai model prediksi performa penjualan PT. Makmur Sumber Redjeki. Analisis deskriptif diterapkan pada metode RFM, sedangkan model *Neural Network* digunakan untuk klasifikasi produk terjual. Evaluasi model *Neural Network*

dilakukan dengan menggunakan metrik akurasi, presisi, recall, dan F1-Score, untuk menilai kemampuan model dalam mengklasifikasikan pelanggan ke dalam kategori Loyal, Potensial, dan Resiko. Selain itu, digunakan *Confusion Matrix* untuk mengidentifikasi tingkat kesalahan klasifikasi pada masing-masing kelas, serta ROC Curve dan Area Under Curve (AUC) untuk mengukur kemampuan model dalam membedakan kelas secara keseluruhan. Sementara itu, evaluasi model RFM dilakukan dengan menganalisis distribusi skor *Recency, Frequency, Monetary* untuk menilai efektivitas segmentasi pelanggan berdasarkan pola pembelian historis. Hasil yang diperoleh dari penerapan metode *Recency, Frequency, Monetary* (RFM) dan *Neural Network* digunakan sebagai dasar untuk menilai kinerja masing-masing model serta menentukan kontribusinya dalam mendukung pengambilan keputusan strategis pada performa penjualan berbasis data.

a. Hasil Optimasi Model *Recency Frequency Monetary* (RFM)

Sebelum dilakukan perbandingan antara kedua model, terlebih dahulu dilakukan proses optimasi terhadap model *Recency, Frequency, Monetary* (RFM). Optimasi ini bertujuan untuk mengidentifikasi tingkat loyalitas pelanggan, pelanggan potensial, serta pelanggan berisiko berdasarkan jumlah penjualan. Pengujian model RFM dilakukan dengan menggunakan variasi data pelanggan teratas top 26 customer.

Tabel 2. Hasil Pengujian Model RFM Berdasarkan 26 Customer

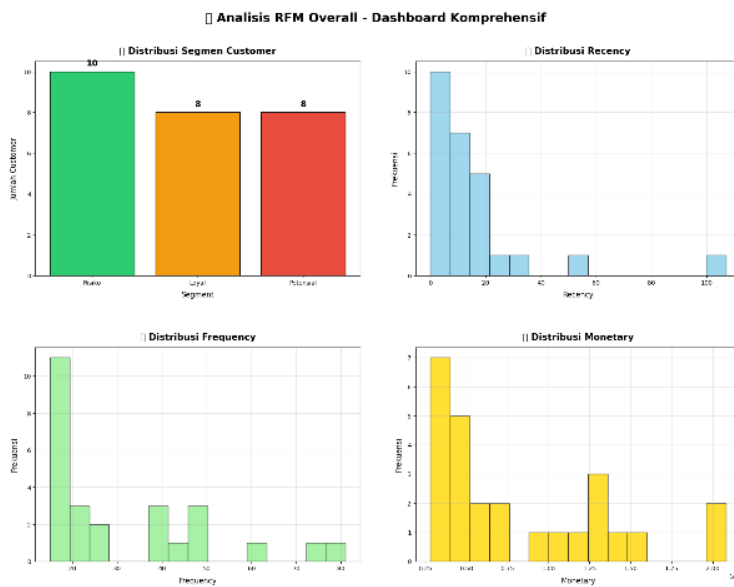
	Recency	Frequency	Monetary
Count	26.00	26.00	2.600000e+01
Mean	16.00	30.77	8.090246e+08
Std	21.61	19.93	5.312792e+08
Min	0.00	15.00	2.808221e+08
25%	4.50	15.00	3.970265e+08
50%	10.00	20.00	5.837023e+08
75%	19.00	43.75	1.215889e+09
Max	107.00	81.00	2.079985e+09

Berdasarkan Tabel 2. Pengujian model *Recency, Frequency, Monetary* (RFM) terhadap 26 data penjualan menunjukkan

kinerja model mencapai tingkat optimal. Pada nilai performa berada pada 75% dan selanjutnya cenderung mengalami stagnasi atau penurunan, yang mengindikasikan terjadinya konvergensi model atau potensi overfitting. Oleh karena itu, parameter RFM 7 dipilih sebagai konfigurasi optimal dalam penerapan model *Recency*, *Frequency*, *Monetary* (RFM).

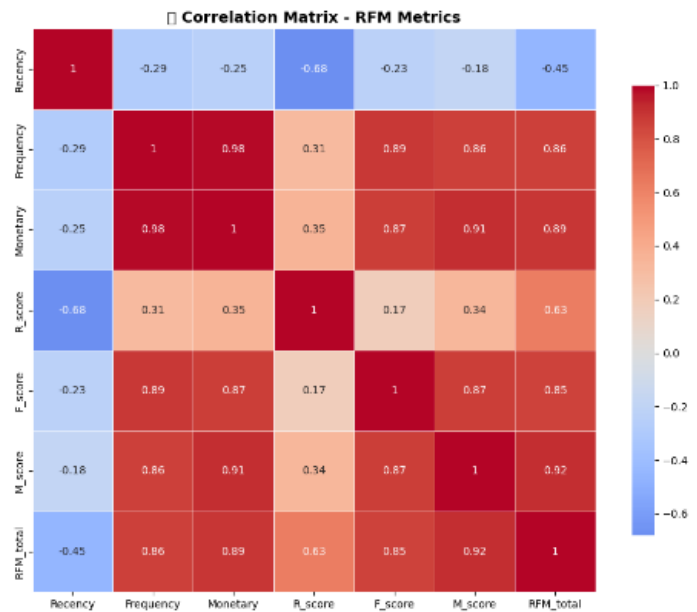
signifikan, dimana sebagian kecil pelanggan memberikan kontribusi nilai penjualan yang tinggi.

Secara keseluruhan, visualisasi ini menegaskan bahwa model RFM mampu merepresentasikan karakteristik pelanggan secara jelas dan konsisten, sehingga efektif digunakan sebagai dasar dalam pengambilan keputusan strategis terkait segmentasi pelanggan, penentuan loyalitas, serta identifikasi pelanggan potensial dan berisiko.



Gambar 2. Matrik Evaluasi *Recency* *Frequency* *Monetary* (RFM)

Pada gambar 2. Menunjukkan hasil analisis menyeluruh model *Recency*, *Frequency*, *Monetary* (RFM) dalam mengelompokkan pelanggan berdasarkan perilaku transaksi. Secara umum, dashboard ini memperlihatkan distribusi segmen pelanggan yang terbagi ke dalam beberapa kategori, yaitu pelanggan bernilai risiko, loyal dan potensial, dengan jumlah yang relatif seimbang. Distribusi variabel *Recency* menunjukkan bahwa sebagian besar pelanggan melakukan transaksi dalam rentang waktu yang relatif dekat, meskipun terdapat beberapa pelanggan dengan jeda transaksi yang cukup panjang. Pada variabel *frequency* terlihat perbedaan intensitas pembelian antar pelanggan, mulai dari frekuensi rendah hingga tinggi. Sementara itu, distribusi *monetary* mengindikasikan variasi nilai transaksi yang



Gambar 3. Correlation Matrix *Recency* *Frequency* *Monetary* (RFM)

Berdasarkan matriks korelasi yang disajikan, terlihat pola hubungan yang kuat dan logis antara metrik-metrik RFM, baik yang berupa nilai mentah maupun skor.

[1] Korelasi Antara Metrik Mentah (*Recency*, *Frequency*, *Monetary*) menunjukkan korelasi yang sangat kuat dan positif ($\rho=0.98$). pelanggan yang sering membeli (*Frequency* tinggi) cenderung juga menghabiskan jumlah uang yang besar (*Monetary* tinggi). *Recency* memiliki korelasi negatif dengan *Frequency* ($\rho=-0.29$) dan *Monetary* ($\rho=-0.25$).

[2] Korelasi Antara Metrik Mentah dan Skor RFM. *Recency* memiliki korelasi negatif yang sangat kuat dengan *R_score* ($\rho=-0.68$). *Frequency* dan *Monetary* memiliki korelasi

yang sangat kuat dan positif dengan skornya masing-masing (F_score dan M_score):

$Frequency$ vs F_score : $\rho=0.89$

$Monetary$ vs M_score : $\rho=0.91$

[3] Korelasi Antar Skor RFM. F_score dan M_score menunjukkan korelasi yang sangat kuat dan positif ($\rho=0.92$). R_score memiliki korelasi yang lemah hingga sedang dengan F_score ($\rho=0.17$) dan M_score ($\rho=0.34$).

[4] korelasi dengan RFM Total. (R_score , F_score , dan M_score) menunjukkan korelasi yang sangat kuat dengan F_score ($\rho=0.85$) dan M_score ($\rho=0.92$). korelasi $Recency$ ($\rho=-0.45$) dan R_score ($\rho=0.63$) lebih rendah.

Perhitungan manual:

$$PX.Y = \frac{\sum_{i=1}^n (X_i - X) (Y_i - Y)}{\sqrt{\sum_{i=1}^n (X_i - X)^2} \sqrt{\sum_{i=1}^n (Y_i - Y)^2}}$$

Dimana :

- X_i dan Y_i adalah nilai individu dari $Frequency$ dan $Monetary$.
- X dan Y adalah rata-rata (mean) dari $Frequency$ dan $Monetary$.
- n adalah jumlah total observasi/pelanggan.

Langkah 1 : Hitung Rata-rata (X dan Y)

$$X = \frac{\sum X_i}{n} = \frac{35}{5} = 7$$

$$Y = \frac{\sum Y_i}{n} = \frac{4500}{5} = 900$$

Langkah 2 : hitung selisih dari rata-rata dan kuadratnya

Tabel 3. Nilai Hasil Rata-rata

No	X_i	Y_i	$(X_i - X)$	$(Y_i - Y)$	$(X_i - X) (Y_i - Y)$	$(X_i - X)^2$	$(Y_i - Y)^2$
1	2	200	-5	-700	3500	25	4900
2	5	650	-2	-250	500	4	62500
3	8	1000	1	100	100	1	10000
4	9	1200	2	300	600	4	90000
5	11	1450	4	550	2200	16	302500
Total					6900	50	955000

Langkah 3 : hitung koefisien korelasi ($\rho_{x,y}$)
Substitusikan nilai total dari tabel 3 ke dalam korelasi.

Rumus Manual :

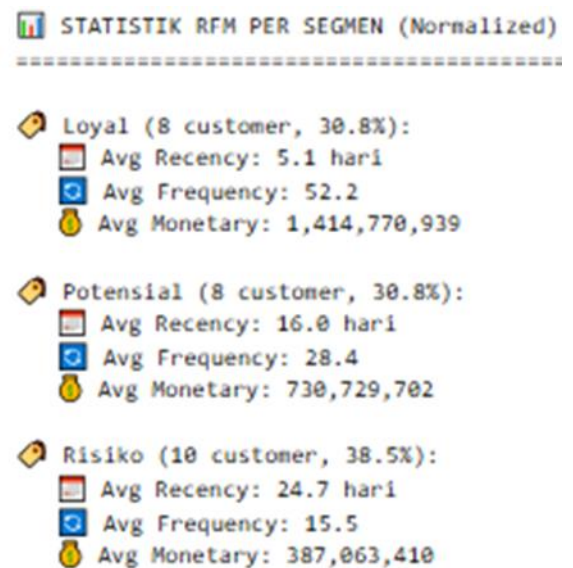
$$\rho_{x,y} = \frac{\sum (X_i - X) (Y_i - Y)}{\sqrt{\sum (X_i - X)^2} \sqrt{\sum (Y_i - Y)^2}}$$

$$= \frac{6900}{\sqrt{50} \sqrt{955000}}$$

$$= \frac{6900}{\sqrt{47750000}}$$

$$= \frac{6900}{6910.137} = 0.9985$$

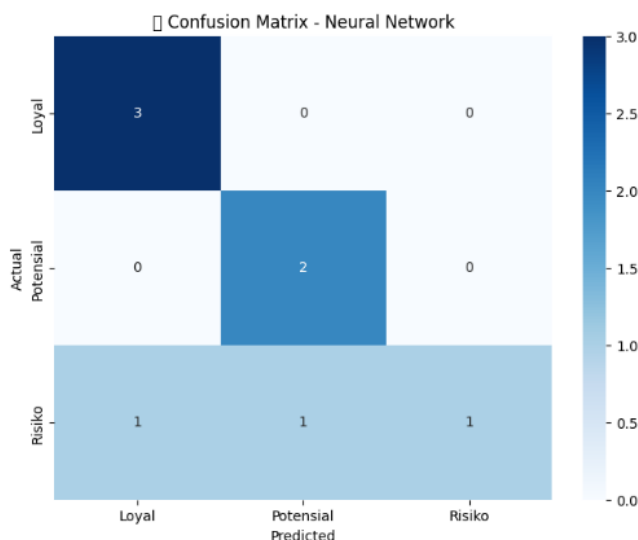
Nilai sebesar 0.9985 sangat mendekati nilai 0.98 pada matriks Korelasi antara variabel $Frequency$ dan $Monetary$, yang menegaskan adanya hubungan korelasi positif yang sangat kuat antara kedua metrik tersebut.



Gambar 4. Statistik RFM per segmen

Hasil analisis menunjukkan bahwa perusahaan memiliki 30,8% pelanggan loyal yang menjadi contributor utama pendapatan dan perlu dipertahankan. 30.8% pelanggan potensial memiliki peluang besar untuk ditingkatkan loyalitasnya melalui penerapan strategi pemasaran yang tepat. Sementara itu, 38.5% pelanggan berada dalam kategori risiko, sehingga memerlukan perhatian dan

penangan khusus agar tidak sepenuhnya berhenti melakukan transaksi.



Gambar 5. Confusion Matrix – Neural Network

Berdasarkan pada gambar 5. *confusion matrix* model *Neural Network* menunjukkan bahwa proses klasifikasi segmen pelanggan dilakukan dengan tingkat keberhasilan yang bervariasi pada setiap segmen. *Confusion matrix* tersebut merepresentasikan klasifikasi multikelas yang terdiri atas segmen pelanggan, yaitu Loyal, Potensial, dan Risiko, dengan total 8 sampel data. Distribusi nilai pada matriks menunjukkan jumlah prediksi benar dan salah pada masing-masing segmen, sehingga dapat digunakan untuk mengevaluasi kemampuan model *Neural Network* dalam membedakan setiap segmen pelanggan secara akurat.

Tabel 4. Klasifikasi Multi-kelas

Aktual / Prediksi	Loyal	Potensial	Risiko	Total Aktual
Loyal	TP _{Loyal} = 3	FPL _{Loyal} = 0	FPL _{Loyal} = 1	4
Potensial	FPP _{Pot} = 0	TPP _{Pot} = 2	FPP _{Pot} = 1	3
Risiko	FN _{Loyal} = 0	FN _{Pot} = 0	TP _{Risiko} = 1	1
Total Prediksi	3	2	3	Total Sampel = 8

Catatan: Dalam *multi-class*, TP (*True Positive*) adalah sel yang benar di diagonal. FP (*False Positive*) adalah kesalahan di baris yang sama. FN (*False Negative*) adalah kesalahan di kolom yang sama.

Langkah 1 : Perhitungan Akurasi
Keseluruhan Akurasi mengukur proporsi total prediksi yang benar dari sampel.

$$\text{Akurasi} = \frac{\text{jumlah prediksi benar (diagonal)}}{\text{total sampel}}$$

$$\text{Akurasi} = \frac{TP_{loyal} + TP_{Potensial} + TP_{Risiko}}{\text{Total Sampel}}$$

$$\text{Akurasi} = \frac{3 + 2 + 1}{3 + 0 + 0 + 0 + 2 + 0 + 1 + 1 + 1}$$

$$\text{Akurasi} = \frac{6}{8} = 0.75$$

Akurasi = 75.0 %

Langkah 2 : Perhitungan Presisi (Precision) kategori

$$\text{Presisi} = \frac{TP}{\text{total prediksi}}$$

$$\text{Presisi loyal} = \frac{3}{3 + 0 + 1} = \frac{3}{4} = 0.75 (75.0\%)$$

$$\text{Presisi potensial} = \frac{2}{0 + 2 + 1} = \frac{2}{3} = 0.67 (66.7 \%)$$

$$\text{Presisi risiko} = \frac{1}{0 + 1 + 1} = \frac{1}{2} = 0.50 (50\%)$$

Langkah 3 : Perhitungan Recall kategori

$$\text{Recall kategori} = \frac{TP}{\text{total aktual}}$$

$$\text{Recall loyal} = \frac{3}{4} = 75\%$$

$$\text{Recall potensial} = \frac{2}{3} = 67\%$$

$$\text{Recall Risiko} = \frac{1}{3} = 0.33 (33\%)$$

Proses melalui tahapan pengumpulan dan pengolahan data yang telah dilakukan, penelitian ini menghasilkan klasifikasi data

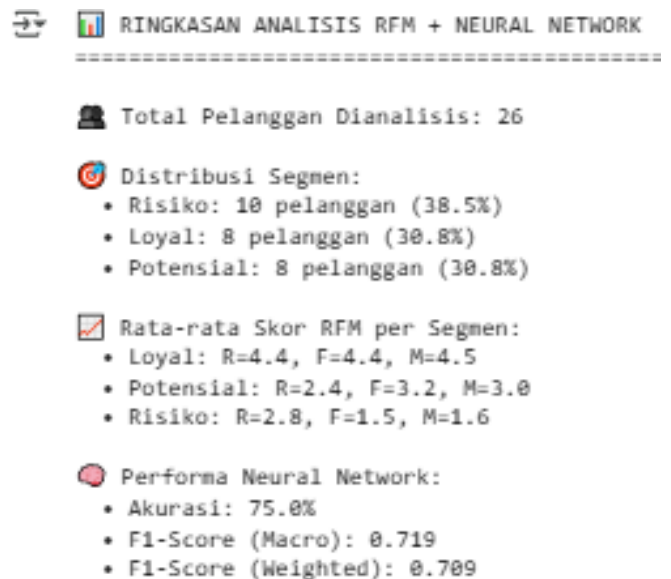
imigrasi ke dalam tiga kategori utama, yaitu Loyal, Potensial, dan Risiko. Proses penambangan data menggunakan bahasa pemrograman Python dengan parameter yang telah ditetapkan mampu mengelompokkan data secara sistematis dan konsisten. Hasil akhir penelitian ini menunjukkan bahwa pendekatan yang digunakan efektif dalam mendukung pencapaian khususnya mengidentifikasi karakteristik dan segmentasi data berdasarkan tingkat loyalitas, potensial dan risiko.

Preview 10 baris pertama:

ID	Tanggal	Nama_Pembeli	Nama_Barang	ID_Product	Tipe	Stok	Terjual	Harga_Jual	Rating	Komentar_C	
0	C001	2024-09-03	PT CAHAYA ABADI	Buku Tulis	P001	Alat Tulis	29	5	4211379	2.4	Alkan beli la
1	C001	2024-03-23	PT CAHAYA ABADI	Buku Tulis	P001	Alat Tulis	94	1	2213462	4.8	Pelayanan toko mer
2	C001	2024-10-18	PT CAHAYA ABADI	Pulpen	P001	Alat Tulis	37	12	1404690	2.3	Harga terjangkau dan kua
3	C001	2024-06-14	PT CAHAYA ABADI	Pulpen	P001	Alat Tulis	95	19	2473220	3.6	Barang bagus dan sesuai i
4	C001	2024-09-20	PT CAHAYA ABADI	Buku Tulis	P001	Alat Tulis	64	2	2750632	2.7	Kualitas kurang mer
5	C002	2024-07-19	PT GLOBAL TECHNOLOGI	Buku Tulis	P001	Alat Tulis	59	4	3948934	1.4	Pengiriman cepat di
6	C002	2024-12-04	PT GLOBAL TECHNOLOGI	Pulpen	P001	Alat Tulis	49	3	1110389	2.3	Harga terjangkau dan kua
7	C002	2024-03-18	PT GLOBAL TECHNOLOGI	Pulpen	P001	Alat Tulis	39	4	4672724	3.1	Proses pemesanan mudah d
8	C002	2024-07-29	PT GLOBAL TECHNOLOGI	Pulpen	P001	Alat Tulis	54	20	3429160	3.1	Alkan beli la
9	C002	2024-05-24	PT GLOBAL TECHNOLOGI	Buku Tulis	P001	Alat Tulis	24	14	4507075	4.4	Stok terbatas tap

Gambar 6. Hasil Proses Data Penjualan

Pada Gambar 6, data yang disajikan memberikan gambaran mengenai kinerja penjualan, tingkat kepuasan pelanggan, serta upaya peningkatan kualitas produk yang mendukung perumusan dan penerapan strategi pemasaran.



Gambar 7. Pemodelan Data RFM dan NN

Berdasarkan hasilnya, pelanggan terbagi menjadi tiga segmen yaitu Risiko (38,5%), Loyal (30,8%), dan Potensial (30,8%). Hasil optimasi model *Neural Network* (NN) menunjukkan kinerja klasifikasi yang juga tinggi. Berdasarkan *confusion matrix*, model *Neural Network* (NN) mencapai akurasi keseluruhan sebesar 75%, dengan presisi 75% untuk segmen loyal, 66,7% untuk segmen potensial, dan 50% untuk segmen Risiko. Recall tertinggi juga mencapai oleh segmen Loyal (75%), diikuti Potensial (67%), sementara segmen Risiko relatif sulit diidentifikasi dengan recall 33%. Hasil penelitian ini juga dapat dikaitkan dengan studi-studi terdahulu, misalnya, penelitian oleh [9] yang menggunakan model *Regency Frequency Monetary* (RFM) menyatakan bahwa analisis klaster berdasarkan nilai pelanggan menggunakan metode RFM dan Matrik nilai pelanggan menunjukkan bahwa berdasarkan metode RFM, menghasilkan 3 jenis karakteristik pelanggan yaitu pelanggan setia (loyal), pelanggan baru (potensial), pelanggan hilang (risiko). Sementara berdasarkan metode matriks nilai pelanggan menghasilkan 2 jenis karakteristik pelanggan, yaitu pelanggan terbaik dan pelanggan yang tidak pasti. Penelitian oleh [10] RFM menghasilkan nilai karakteristik

pelanggan yang merepresentasikan tingkat keterkinian transaksi, frekuensi penggunaan layanan, dan kontribusi nilai finansial. Penelitian oleh [11] menunjukkan adanya perbedaan karakteristik pelanggan berdasarkan tingkat keterkinian transaksi, intensitas penggunaan, dan kontribusi nilai finansial, yang dapat dimanfaatkan sebagai dasar segmentasi dan penyusunan strategi yang lebih tepat. Demikian pula, studi oleh [12] model NN menghasilkan informasi yang bermanfaat untuk mendukung pengambilan keputusan bisnis, khususnya dalam memahami pola pembelian dan penyusunan strategi penjualan yang lebih tepat. Selanjutnya, studi oleh [13] menunjukkan bahwa penerapan *neural network* (NN) mampu memodelkan pola hubungan data secara efektif dan meningkatkan akurasi analisis dibandingkan pendekatan konvensional, model NN berhasil mengolah variabel yang digunakan sehingga memberikan hasil yang lebih optimal dan mendukung pengambilan keputusan berbasis data. Selanjutnya, studi oleh [14] Menunjukkan Model NN mampu mengenali pola non-linear antar variabel (RFM) dengan cluster penjualan. Akurasi prediksi kategori pelanggan meningkat hingga 95%, dengan kemampuan segmen. Dalam studi oleh [15] RFM + NN menghasilkan lima segmen pelanggan : *core loyalists, potential loyalists, price-sensitive buyers, new customers, dan inactive users*.

Integrasi model RFM dengan NN dapat menjadi penguatan hasil analisis yang telah dilakukan, jika RFM dan Matriks nilai pelanggan menghasilkan tiga dan dua segmen, penerapan NN dapat memperluas hasil menjadi lebih dinamis dan prediktif. Oleh karena itu, metode ini tidak hanya mengelompokkan pelanggan berdasarkan data historis, tetapi juga memprediksi kecenderungan perilaku di masa depan, dengan pelanggan yang berpotensi menjadi loyal atau sebaliknya

4. SIMPULAN

Berdasarkan penelitian yang dilakukan pada PT. Makmur Sumber Redjeki, penerapan model RFM + NN (*Neural Network*) memberikan dampak signifikan terhadap peningkatan efektivitas strategi pemasaran dan manajemen pelanggan. Hasil analisis menunjukkan bahwa perusahaan mampu mengelompokkan pelanggan ke dalam beberapa segmen utama, yaitu pelanggan loyal, potensial, dan risiko. Dengan demikian, hasil optimal model *Neural Network* menunjukkan bahwa kinerja klasifikasi yang dicapai berada pada tingkat sedang hingga baik, RFM dengan Resiko 38,5%, Loyal 30,8% dan Potensial 30,8% dan *Neural Network* meningkatkan akurasi 75% yang menunjukkan bahwa kemampuan model dalam mengklasifikasikan setiap segmen pelanggan masih bervariasi dan selaras dengan distribusi hasil segmentasi yang diperoleh.

Segmentasi yang dihasilkan membantu perusahaan dalam menentukan prioritas pelayanan serta merumuskan strategi promosi yang disesuaikan dengan karakteristik masing-masing kelompok pelanggan. Hasil penelitian ini menunjukkan bahwa penerapan model RFM dan *Neural Network* merupakan solusi yang efektif dalam menganalisis perilaku pelanggan pada sector bisnis ritel dan e-commerce. Melalui pendekatan ini, perusahaan dapat memahami dinamika loyalitas pelanggan secara lebih mendalam serta mengoptimalkan strategi pemasaran berbasis data (*data driven marketing*).

DAFTAR PUSTAKA

- [1] A. Hermawan, F. Aditama, L. R. Ramadhani, and N. Ilmalani, "Analisis Segmentasi Pelanggan Berbasis RFM dan Evaluasi Efektivitas Kampanye Pemasaran untuk Meningkatkan Retensi," *Neptunus: Jurnal Ilmu Komputer dan Teknologi Informasi*, vol. 2, no. 4, 2024.

- [2] M. M. Yuniar and R. Ambarwati, "Prediction Analysis of Retail Store Sales Level using Neural Network Algorithm Method based on Customer Segments [Analisis Prediksi Tingkat Penjualan Toko Ritel menggunakan Metode Algoritma Neural Network berbasis Segmen Pelanggan]," pp. 1–11.
- [3] A. N. M. Hadi Yansah, E. Y. Puspaningrum, and A. M. Rizky, "Implementasi Kombinasi Metode Rfm Dan Algoritma Kmeans Untuk Klasterisasi Penjualan Minuman Kemasan," *Pros. Semin. Nas. Inform. Bela Negara*, vol. 2, pp. 122–126, 2021, doi: 10.33005/santika.v2i0.96.
- [4] I. Lewaaelhamd, "Customer Segmentation Using Machine Learning Model: An Application of RFM Analysis," *J. Data Sci. Intell. Syst.*, vol. 2, no. 1, pp. 29–36, 2023, doi: 10.47852/bonviewjdsis32021293.
- [5] K. Nugroho, W. Hadi Kurniawati, and R. M. Herdian Bhakti, "Perancangan Sales Prediction Model Menggunakan Metode Neural Network," *J. Ilm. Intech Inf. Technol. J. UMUS*, vol. 4, no. 02 SE-Articles, pp. 153–160, Nov. 2022, doi: 10.46772/intech.v4i02.870.
- [6] Z. Jiang, K. Anderson, and D. Stafylas, "Predicting future earnings changes : a modest integration of artificial neural networks and financial factors
Keywords : Machine learning ; Earnings prediction ANN - artificial neural network AUC - area under the ROC Curve ML- machine learning RF - random".
- [7] A. Firmansyah and M. Akbar, "Implementasi Neural Network Untuk Prediksi Penjualan Produk (Studi Kasus Penjualan Siomay)," *Progresif J. Ilm. Komput.*, vol. 18, no. 1, p. 115, 2022, doi: 10.35889/progresif.v18i1.808.
- [8] M. Seyedan and F. Mafakheri, "Predictive big data analytics for supply chain demand forecasting : methods , applications , and research opportunities," *J. Big Data*, 2020, doi: 10.1186/s40537-020-00329-2.
- [9] T. Juhari, A. Juarna, and U. Gunadarma, "Implementation Rfm Analysis Model For Customer Segmentation Using The K-Means Algorithm Case Study XYZ," *EXPLORE* vol. 12, no. 1, pp. 107–118, 2022.
- [10] D. S. Nugaha, I. Thoib, N. Sururi, F. B. F, and B. P. Candra, "Segmentasi Pelanggan Berbasis Analisis RFM Menggunakan Algoritma K- Means Clustering," *Jurnal Komputer Teknologi Informasi Sistem Komputer (JUKTISI)*, vol. 4, no. 2, pp. 1361–1369, 2025.
- [11] I. Yunita, P. R. Ali, M. A. Kartawidjaja, and R. Sukwadi, "Segmentasi Pelanggan Menggunakan K-Means Clustering : Menganalisis Metrik RFM untuk Strategi Pemasaran," *Jurnal Media Teknik Dan Sistem Industri*, vol. 9, no. 1, pp. 58–66, 2025, doi: 10.35194/jmtsi.v9i1.4452.
- [12] N. Putri, M. Z. Sarwani, and R. Hariyanto, "Implementasi Association Rule Pada Transaksi Penjualan Menggunakan Metode Neural Network Backpropagation," *INTEGER: Journal of Information Technology*, vol. 9, no 2, pp. 173–184, 2024.
- [13] Budi Mulyono and Nursalim, "Prediksi Rentet Waktu Penjualan Barang Menggunakan Algoritma Backpropagation," *J. Kolaboratif Sains*, vol. 6, no. 2, pp. 131–139, 2023, doi: 10.56338/jks.v6i2.3300.
- [14] M. S. Kasem, "Customer profiling , segmentation , and sales prediction using AI in direct marketing," *Neural Comput. Appl.*, vol. 36, no. 9, pp. 4995–5005, 2024, doi: 10.1007/s00521-023-09339-6.

- [15] Y. Putri, D. Aldo, and W. Ilham, ,
“Retail Marketing Strategy
Optimization : Customer
Segmentation with Artificial
Intelligence Integration and K-Means
Clustering,” *Sinkron : Jurnal dan
Penelitian Teknik Informatika*, vol. 8,
no. 4, pp. 2155–2163, 2024.