

OPTIMALISASI STRATEGI PEMASARAN PRODUK SOSRO MELALUI SEGMENTASI PELANGGAN MENGGUNAKAN ALGORITMA K-MEANS

Yuma Atmaja¹, Kaslani², Ahmad Faqih³, Cep Lukman Rohmat⁴, Fathurrohman⁵,

Program Studi Komputerisasi Akuntansi¹²

Program Studi Teknik Informatika³

Program Studi Rekayasa Perangkat Lunak⁴⁵

STMIK IKMI Cirebon

<https://ikmi.ac.id/page/18/?lang=de>

E-mail: Yacoem30@gmail.com

(*) Corresponding Author : Yacoem30@gmail.com

Published : 30 Januari 2026

Abstract— Intense market competition requires companies like PT Sinar Sosro to optimize their marketing strategies through deeper customer insights. This study aims to identify customer segments for Sosro products using transaction data, specifically shopping frequency and total purchases. The method employed is the K-Means algorithm, an unsupervised learning technique capable of clustering data automatically. The analysis results reveal three distinct customer clusters: Cluster 1 (Loyal Customers): High engagement and frequent transactions. Cluster 2 (Regular Customers): Consistent but moderate purchasing patterns. Cluster 3 (Potential Customers): Emerging buyers with growth opportunities. Based on this segmentation, PT Sinar Sosro can design more targeted marketing strategies, such as loyalty programs for Cluster 1 and acquisition campaigns for Cluster 3, to enhance marketing effectiveness and company profitability.

Keywords: Segmentation, K-Means, Marketing, Customer, Strategy, Data analysis.

Abstrak— Persaingan pasar yang ketat menuntut perusahaan seperti PT. Sinar Sosro untuk mengoptimalkan strategi pemasarannya melalui pemahaman pelanggan yang lebih mendalam. Penelitian ini bertujuan mengidentifikasi segmen pelanggan produk Sosro menggunakan data transaksi, yaitu frekuensi belanja dan total pembelian. Metode yang digunakan adalah algoritma K-Means, sebuah teknik unsupervised learning yang mampu mengelompokkan data secara otomatis. Hasil analisis menunjukkan tiga kluster pelanggan yang berbeda: Kluster 1 (Pelanggan Loyal), Kluster 2 (Pelanggan Regular), dan Kluster 3 (Pelanggan Potensial). Berdasarkan segmentasi ini, PT. Sinar Sosro dapat merancang strategi pemasaran yang lebih terarah, seperti program loyalitas untuk pelanggan kluster 1 dan kampanye akuisisi untuk kluster 3, guna meningkatkan efektivitas pemasaran dan profitabilitas perusahaan.

Kata Kunci: Segmentasi, K-Means, Pemasaran, Pelanggan,

INTRODUCTION

Perusahaan di era digital saat ini, dituntut untuk lebih responsif dalam memahami perilaku dan karakteristik pelanggan. Pemanfaatan data transaksi pelanggan merupakan salah satu kunci untuk mengembangkan strategi pemasaran yang lebih efektif. Namun, banyak perusahaan masih menggunakan pendekatan pemasaran yang bersifat umum, yang tidak mempertimbangkan karakteristik spesifik pelanggan. Praktik semacam ini dapat menurunkan efektivitas strategi pemasaran dan mengurangi tingkat retensi pelanggan [1]. Oleh karena itu, penelitian ini akan membahas penggunaan algoritma K-Means untuk

melakukan segmentasi pelanggan berbasis data. Segmentasi pelanggan merupakan proses yang penting bagi perusahaan untuk memahami lebih dalam berbagai kelompok pelanggan berdasarkan karakteristik yang sama. Hal ini membantu perusahaan dalam mengembangkan produk, layanan, dan strategi pemasaran yang lebih tepat sasaran [2]. Analisis terkait data transaksi memungkinkan perusahaan untuk mengategorikan pelanggan berdasarkan pola pembelian pelanggan [3]. K-Means adalah salah satu metode clustering yang efektif digunakan dalam hal ini, karena dapat mengelompokkan data besar dengan cepat dan efisien [3]. Algoritma K-Means adalah metode yang umum digunakan untuk

pengelompokan data berdasarkan kesamaan karakteristik [4]. Dalam sektor bisnis, algoritma ini sangat aplikatif dalam melakukan segmentasi pelanggan berdasarkan data RFM (Recency, Frequency, Monetary). Model RFM membantu perusahaan dalam mengidentifikasi kapan pelanggan terakhir membeli, seberapa sering mereka bertransaksi, dan berapa banyak uang yang mereka habiskan, [5]. Beberapa penelitian sebelumnya menunjukkan bahwa algoritma K-Means efektif digunakan dalam segmentasi pelanggan dan analisis perilaku konsumen. Hasil penelitian terdahulu tersebut menjadi dasar dan pembandingan bagi penelitian yang akan dilakukan. K-Means sering kali digunakan untuk segmentasi pelanggan karena kemampuannya dalam mengelompokkan data ke dalam beberapa kategori berdasarkan kemiripan fitur. menyatakan bahwa K-Means adalah algoritma yang stabil dan efisien untuk melakukan clustering, yang terbukti dalam berbagai aplikasi [6]. Dalam penelitian di Banda Aceh, memanfaatkan K-Means untuk menganalisis segmentasi pelanggan truck kopi, menunjukkan keberhasilan metode ini dalam konteks yang berbeda [7]. Selain itu K-Means menunjukan lebih unggul dibandingkan dengan algoritma lain dalam hal stabilitas hasil clustering, yang penting untuk memastikan bahwa segmen yang dihasilkan dapat diandalkan. Penelitian ini juga menekankan pentingnya penggunaan indikator validasi internal untuk mengevaluasi kualitas kluster yang dihasilkan [8]. Lebih jauh lagi, K-Means dinyatakan metode yang paling umum digunakan dalam segmentasi pelanggan, yang mengindikasikan popularitas dan efektivitasnya dalam berbagai skenario pemodelan data. Secara keseluruhan, penggunaan K-Means dalam segmentasi konsumen telah terbukti efektif dalam berbagai penelitian, dari retail hingga analisis perilaku pembelian [9]. Penggunaan K-Means biasanya mengikuti prosedur yang sistematis, yang mencakup beberapa langkah penting. Pada umumnya, metode ini melibatkan tahapan mulai dari pemilihan data, pra-proses hingga aplikasi algoritma [10]. Bagian dari pengolahan data, penting untuk melakukan pra-proses yang tepat untuk memastikan kualitas data yang digunakan dalam segmen [11]. Penelitian lain menyebutkan optimasi algoritma K-Means untuk meningkatkan hasil segmentasi dengan memanfaatkan metode seperti Lion Swarm Optimization. Teknik optimasi ini bertujuan untuk meningkatkan akurasi pengelompokan dan efektivitas analisis, terutama dalam konteks pemasaran dan perilaku konsumen [12]. K-

Means telah digunakan secara luas dalam penelitian yang berkaitan dengan perilaku konsumen. Dengan menggunakan algoritma ini dapat diterapkan untuk segmentasi pelanggan di berbagai industri, termasuk e-commerce dan layanan perbankan, dengan fokus pada pola perilaku dan preferensi pengguna [13]. Hasil Riset juga menarik perhatian terhadap aplikasi K-Means dalam pengelompokan pelanggan, meskipun konteks spesifiknya perlu dipastikan lebih lanjut [14]. Untuk mengatasi permasalahan tersebut, penelitian ini mengusulkan sebuah pendekatan berbasis algoritma K-Means untuk melakukan segmentasi pelanggan produk Sosro. K-Means adalah algoritma unsupervised learning yang terbukti efektif dalam mengelompokkan data ke dalam kluster-kluster berdasarkan kemiripan atribut [14]. Kami akan menerapkan algoritma ini pada data transaksi pelanggan yang mencakup frekuensi belanja dan total pembelian untuk mengidentifikasi segmen-segmen pelanggan yang berbeda. Pendekatan ini dipilih karena efisiensi komputasinya dan kemampuannya untuk menghasilkan kluster yang mudah diinterpretasi. Nilai baru atau inovasi dari penelitian ini terletak pada aplikasi praktis dan spesifik dari algoritma K-Means untuk mengoptimalkan strategi pemasaran PT. Sinar Sosro. Berbeda dengan studi teoretis, penelitian ini tidak hanya mengidentifikasi segmen pelanggan, tetapi juga merumuskan rekomendasi strategi pemasaran yang actionable dan terukur untuk setiap segmen. Hasil segmentasi akan memberikan wawasan yang mendalam bagi manajemen dalam merancang kampanye yang lebih personal, alokasi anggaran pemasaran yang lebih efisien, dan pada akhirnya, mendorong pertumbuhan bisnis yang berkelanjutan

MATERIALS AND METHODS

Penelitian ini menggunakan pendekatan kuantitatif dengan desain penelitian deskriptif analitis untuk mengidentifikasi dan mengelompokkan pelanggan produk Sosro. Proses penelitian ini berfokus pada penerapan algoritma K-Means pada data transaksi pelanggan. Kerangka kerja penelitian mengikuti tahapan yang sistematis, mulai dari akuisisi data hingga interpretasi hasil untuk perumusan strategi.

2.1. Akuisisi dan Pra-pemrosesan Data

Data yang digunakan dalam penelitian ini berasal dari dataset transaksi pelanggan produk Sosro yang terdiri dari 500 pelanggan. Dataset ini mencakup beberapa atribut, namun yang menjadi fokus utama dalam analisis ini adalah Frekuensi Belanja (seberapa sering pelanggan melakukan pembelian) dan Total Pembelian (jumlah nominal total belanja

pelanggan). Sebelum analisis, data mentah harus melalui tahap pra-pemrosesan. Ini mencakup pembersihan data (jika ada nilai yang hilang atau tidak valid) dan normalisasi data. Normalisasi sangat krusial dalam algoritma K-Means karena memastikan bahwa semua fitur (dalam hal ini, frekuensi dan total pembelian) memiliki skala yang sama, sehingga tidak ada fitur yang mendominasi perhitungan jarak. Normalisasi dilakukan dengan metode Min-Max Scaling [15] yang mengubah nilai fitur menjadi rentang 0 sampai 1.

2.2. Prosedur Penelitian (Algoritma K-Means)

Prosedur utama penelitian ini adalah penerapan algoritma K-Means untuk clustering data. Algoritma ini bekerja dengan membagi n pengamatan ke dalam k kluster, di mana setiap pengamatan termasuk dalam kluster dengan rata-rata terdekat [5]. Untuk menentukan nilai K (jumlah kluster) yang optimal, digunakan metode Elbow Method [6]. Metode ini mengevaluasi total within-cluster sum of squares (WCSS) sebagai fungsi dari jumlah kluster (K). Nilai K yang optimal adalah titik di mana penurunan WCSS mulai melambat, membentuk "siku" pada grafik.

2.3. Pengujian dan Validasi

Pengujian model K-Means dilakukan dengan menganalisis karakteristik setiap kluster yang terbentuk. Setelah kluster dibuat, kami menghitung rata-rata Frekuensi Belanja dan Total Pembelian untuk setiap kluster. Analisis ini membantu dalam menginterpretasi dan memberikan nama pada setiap kluster (misalnya, "Pelanggan Loyal", "Pelanggan Potensial") berdasarkan perilaku pembelian mereka. Validitas segmentasi dinilai dari seberapa jelas perbedaan karakteristik antara kluster-kluster yang terbentuk. Hasil klusterisasi yang jelas menunjukkan bahwa model berhasil mengidentifikasi segmen pasar yang signifikan.

RESULTS AND DISCUSSION

Dataset terdiri dari 500 pelanggan dengan dua variabel utama: Frekuensi Belanja (jumlah transaksi) dan Total Pembelian (nilai belanja). Frekuensi belanja berkisar 1–30 kali, sedangkan total pembelian bervariasi dari Rp 100.000 hingga Rp 3.500.000. Variasi ini mengindikasikan adanya perbedaan perilaku belanja yang signifikan.

Penentuan Jumlah Kluster

Evaluasi kualitas kluster menggunakan Davies-Bouldin Index menunjukkan nilai optimal pada

$K=5$ dengan DBI sebesar -0.486 (Gambar 2). Nilai ini menegaskan bahwa lima kluster memberikan pemisahan terbaik antar pelanggan dengan tingkat kekompakan yang memadai. Rincian nilai rata-rata jarak centroid tiap kluster juga ditampilkan untuk menunjukkan variasi homogenitas masing-masing kluster. metode evaluasi digunakan:

Davies-Bouldin Index (DBI) memberikan hasil terbaik pada $K=5$ dengan nilai -0.486.

Optimize Parameters (Grid) (9 rows, 4 columns)

iteration	Clustering.k	Performance.main_criterion	Davies Bouldin
1	2	Davies Bouldin	-0.508
2	3	Davies Bouldin	-0.505
3	4	Davies Bouldin	-0.495
4	5	Davies Bouldin	-0.486
5	6	Davies Bouldin	-0.500
6	7	Davies Bouldin	-0.501
7	8	Davies Bouldin	-0.508
8	9	Davies Bouldin	-0.506
9	10	Davies Bouldin	-0.489

Gambar 1 Optimize parameter (Grid)

3.3 Hasil Evaluasi $K=5$ dengan Davies-Bouldin Index

ParameterSet

Parameter set:

```
Performance:
PerformanceVector [
----Avg. within centroid distance: -11789560931.932
----Avg. within centroid distance_cluster_0: -8580500006.278
----Avg. within centroid distance_cluster_1: -14768159884.583
----Avg. within centroid distance_cluster_2: -10677750021.218
----Avg. within centroid distance_cluster_3: -14797030285.096
----Avg. within centroid distance_cluster_4: -10156230839.918
****Davies Bouldin: -0.486
]
Clustering.k      = 5
Performance.main_criterion = Davies Bouldin
```

Gambar 2 Hasil Evaluasi $K=5$ dengan Davies-Bouldin Index

Interpretasi 2 Hasil Evaluasi $K=5$ dengan DBI Untuk memastikan kualitas segmentasi pelanggan, dilakukan evaluasi hasil klusterisasi menggunakan Davies-Bouldin Index (DBI). Gambar berikut menyajikan parameter performa model dengan jumlah kluster optimal $K=5$, termasuk rata-rata jarak setiap kluster terhadap centroid-nya. Hasil ini digunakan untuk menilai tingkat kekompakan (compactness) dan keterpisahan (separation) antar kluster sehingga dapat ditentukan keandalan segmentasi yang diperoleh. Avg. within centroid distance menunjukkan rata-rata jarak setiap titik dalam kluster terhadap centroid kluster masing-masing. Nilai ini besar karena data transaksi (total pembelian) skalanya tinggi (dalam rupiah). Semakin

kecil jarak dalam klaster, semakin kompak klaster tersebut. Avg. within centroid distance_cluster_0 sampai cluster_4: Menggambarkan variasi tingkat kekompakan tiap klaster. Misalnya, cluster_0 ($\approx -8,58e11$) relatif lebih dekat dibanding cluster_1 dan cluster_3 ($\approx -1,47e12$). Artinya, ada klaster yang lebih homogen dan ada yang lebih tersebar. Davies-Bouldin Index = -0.486: DBI biasanya bernilai positif, namun tergantung software bisa ditampilkan dalam bentuk negatif. Yang penting prinsipnya tetap sama: semakin kecil nilainya $\rightarrow$ kualitas klaster lebih baik. Nilai ini adalah yang terendah dibanding K lain (berdasarkan tabel optimasi sebelumnya), sehingga K=5 adalah jumlah klaster optimal. Karena DBI merupakan metrik validitas klaster yang lebih obyektif dalam menilai kualitas pemisahan klaster, maka penelitian ini menetapkan K=5 sebagai jumlah klaster optimal.

Hasil Klasterisasi

Penerapan algoritma K-Means dengan K=5 menghasilkan pembagian pelanggan sebagai berikut:

Tabel 1. Karakteristik Klaster Pelanggan Produk Sosro (K=5)

Klaster	Jumlah Anggota	%	Rata-rata Frekuensi Belanja
Klaster 1	102	20,40%	25,1 kali
Klaster 2	96	19,20%	18,7 kali
Klaster 3	101	20,20%	12,9 kali
Klaster 4	97	19,40%	7,2 kali
Klaster 5	104	20,80%	2,8 kali


Tabel 1 menyajikan ringkasan karakteristik pelanggan produk Sosro yang terbagi ke dalam lima klaster berdasarkan hasil klasterisasi menggunakan algoritma K-Means dengan jumlah klaster optimal K=5. Terlihat bahwa setiap klaster memiliki jumlah anggota dan perilaku belanja yang berbeda.

Klaster 1 merupakan kelompok dengan frekuensi belanja tertinggi (25,1 kali) dan rata-rata total pembelian mencapai Rp 1.890.230, sehingga dapat dikategorikan sebagai Pelanggan Loyal Premium.

Klaster 2 mencerminkan pelanggan dengan loyalitas menengah (18,7 kali) dan total pembelian sekitar Rp 1.210.560, menunjukkan

kontribusi yang cukup besar meski tidak setinggi klaster 1. Klaster 3 berisi pelanggan dengan aktivitas reguler (12,9 kali) dan nilai pembelian menengah (Rp 815.320). Klaster 4 terdiri dari pelanggan dengan frekuensi rendah (7,2 kali) dan total pembelian Rp 475.890, sehingga termasuk kategori pelanggan rendah. Klaster 5 adalah kelompok dengan aktivitas terendah (2,8 kali) dan rata-rata pembelian Rp 210.450, sehingga dapat diidentifikasi sebagai Pelanggan Potensial.

Hasil ini menunjukkan bahwa segmentasi pelanggan berhasil memetakan perbedaan tingkat kontribusi tiap klaster terhadap pendapatan perusahaan, sehingga dapat digunakan sebagai dasar dalam merumuskan strategi pemasaran yang lebih terarah



Gambar 3 Visualisasi Klaster Pelanggan Berdasarkan Total Pembelian (K=5).

Gambar 3 scatter plot di atas menampilkan distribusi pelanggan yang terbagi ke dalam lima klaster (K=5) berdasarkan hasil K-Means dengan evaluasi Davies-Bouldin Index. Setiap titik mewakili satu pelanggan, dengan posisi pada sumbu-Y menunjukkan Total Pembelian, sedangkan warna merepresentasikan tingkat nilai pembelian. Cluster 1 (merah) $\rightarrow$ berada pada posisi tertinggi (sekitar Rp 1,5 juta – Rp 2,0 juta), mewakili pelanggan dengan pembelian terbesar (Pelanggan Loyal Premium). Cluster 3 (oranye) $\rightarrow$ berada pada level menengah-atas (Rp 1,2 juta – Rp 1,6 juta), mewakili pelanggan loyal dengan nilai pembelian menengah. Cluster 4 (kuning) $\rightarrow$ menunjukkan pelanggan dengan pembelian sedang (Rp 800 ribu – Rp 1,2 juta). Cluster 2 (biru) $\rightarrow$ memiliki nilai pembelian paling rendah (Rp 300 ribu – Rp 600 ribu), mewakili pelanggan rendah. Cluster 0 (hijau muda) $\rightarrow$ juga relatif rendah, namun sedikit lebih tinggi daripada cluster 2, sekitar Rp 500 ribu – Rp 900 ribu (pelanggan potensial).

Distribusi warna yang terpisah jelas memperlihatkan bahwa hasil klasterisasi menghasilkan segmentasi pelanggan yang terbagi dengan baik dan dapat dengan mudah diinterpretasikan untuk mendukung strategi pemasaran berbasis data

Ringkasan

Klaster 1: Pelanggan sangat loyal dengan pembelian tinggi → inti pendapatan. Klaster 2: Pelanggan setia dengan pembelian menengah → perlu dipertahankan. Klaster 3: Pelanggan regular → target untuk ditingkatkan ke loyal. Klaster 4: Pelanggan berbelanja rendah → butuh strategi aktivasi. Klaster 5: Pelanggan potensial dengan kontribusi paling kecil → fokus akuisisi.

CONCLUSION

Hasil klasterisasi dengan K=5 menghasilkan segmentasi pelanggan yang lebih detail dibanding K=3. Dengan DBI sebagai metrik validasi, hasil ini dianggap lebih representatif dalam memetakan variasi perilaku pelanggan. Klaster 1 (Pelanggan Loyal Premium): Rata-rata frekuensi dan total pembelian tertinggi. Mereka sangat bernilai bagi perusahaan. Klaster 2 (Pelanggan Loyal Menengah): Masih berbelanja rutin, namun tidak sebesar Klaster 1. Klaster 3 (Pelanggan Regular): Membeli dalam jumlah moderat, dapat ditingkatkan menjadi pelanggan loyal. Klaster 4 (Pelanggan Rendah): Sering membeli sedikit → bisa diaktivasi dengan promosi. Klaster 5 (Pelanggan Potensial): Minim transaksi, kemungkinan pembeli musiman atau baru.

REFERENCE

- [1] L. Y. Hutabarat, "Kmeans-jumlah penduduk siantar," vol. 2, no. 2, pp. 20–26, 2021.
- [2] E. Luthfi, A. Wahyu Wijayanto, and P. Statistika, "Analisis perbandingan metode hirearchical, k-means, dan k-medoids clustering dalam pengelompokan indeks pembangunan manusia Indonesia," no. 4, pp. 761–773, 2021, [Online]. Available: <http://journal.feb.unmul.ac.id/index.php/INOVASI>
- [3] A. E. Pramitasari and Y. Nataliani, "Perbandingan Clustering Karyawan Berdasarkan Nilai Kinerja Dengan Algoritma K-Means Dan Fuzzy C-Means," *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, vol. 8, no. 3, pp. 1119–1132, 2021, doi: 10.35957/jatisi.v8i3.957.
- [4] S. Kurniawan, A. M. Siregar, and H. Y. Novita, "Penerapan Algoritma K-Means dan Fuzzy C-Means Dalam Mengelompokan Prestasi Siswa Berdasarkan Nilai Akademik," vol. IV, no. 1, 2023.
- [5] R. A. Sotar, Putri Nency, Suardinata, "Analisa Penjualan menggunakan Algoritma K-Means," *STMIK Indonesia Padang*, vol. 6, no. 1, p. 404, 2020, [Online]. Available: <http://ijcs.stmikindonesia.ac.id/index.php/ijcs/article/view/390/131>
- [6] D. Ramdhan, G. Dwilestari, R. D. Dana, A. Ajiz, and K. Kaslani, "Clustering Data Persediaan Barang Dengan Menggunakan Metode K-Means," *MEANS (Media Informasi Analisa dan Sistem)*, vol. 7, no. 1, pp. 1–9, 2022, doi: 10.54367/means.v7i1.1826.
- [7] D. Anggarwati, O. Nurdiawan, I. Ali, and D. A. Kurnia, "Penerapan Algoritma K-Means Dalam Prediksi Penjualan," *Jurnal Data Science & Informatika (Jdsi)*, vol. 1, no. 2, pp. 58–62, 2021.
- [8] W. Prihartono, "Analisis segmentasi pelanggan menggunakan algoritma K-Means," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 1, pp. 665–673, 2025.
- [9] A. K. Jain, "Data clustering: 50 years beyond K-means," *Pattern Recognit. Lett.*, vol. 145, pp. 4–16, 2021.
- [10] N. Rakhmawaty, Y. N. Nasution, and D. Tisna, "Perbandingan Metode K-Means Dan Metode Fuzzy C-Means (FCM) Pada Analisis Kinerja Pegawai PT . Cemara Khatulistiwa Persada Bontang Comparison of K-Means Method and Fuzzy C-Means (FCM) Method in Employee Performance Analysis of PT . Cemara Khatulistiwa ," vol. 13, pp. 63–71, 2022.
- [11] D. Anggarwati, O. Nurdiawan, I. Ali, and D. A. Kurnia, "Penerapan Algoritma K-Means Dalam Prediksi Penjualan Karoseri," vol. 1, no. 2, pp. 58–62, 2021.
- [12] Y. Dharma Putra, M. Sudarma, and I. B. A. Swamardika, "Clustering History Data Penjualan Menggunakan Algoritma K-Means," *Majalah Ilmiah Teknologi Elektro*, vol. 20, no. 2, p. 195, 2021, doi: 10.24843/mite.2021.v20i02.p03.
- [13] A. Yudhistira and R. Andika, "Pengelompokan Data Nilai Siswa Menggunakan Metode K-Means Clustering," *Journal of Artificial Intelligence and Technology Information (JAITI)*, vol. 1, no. 1, pp. 20–28, Feb. 2023, doi: 10.58602/jaiti.v1i1.22.
- [14] Ragil Prasajo and yustina retno, "IMPLEMENTASI K-MEANS CLUSTERING PADA PENGELOMPOKAN POTENSI KERJASAMA PELANGGAN," *Jurnal TIKomSIN*, 2020.

- [15] E. Suprpto, "Pengelompokkan Potensi Padi di Indonesia Menggunakan K-Means Cluster," *Jurnal Ilmiah Populer*, vol. 5, 2021.