

Pemodelan Profil Siswa SMP Berdasarkan Mathematics Self-Regulated Learning Menggunakan Metode K-Means Clustering

Munaji¹

¹Teknik Elektro, Universitas 17 Agustus 1945 Cirebon, Cirebon, Indonesia

¹munaji@untagcirebon.ac.id

ABSTRAK

Prestasi matematika di tingkat sekolah menengah pertama (SMP) masih menghadapi tantangan signifikan, di mana faktor non-kognitif seperti self-regulated learning (SRL) memegang peranan penting di samping kemampuan kognitif. Penelitian ini bertujuan mengembangkan model matematis klasifikasi profil Mathematics Self-Regulated Learning siswa SMP di Kota Cirebon menggunakan metode K-Means Clustering. Desain penelitian yang digunakan adalah deskriptif-eksploratif kuantitatif dengan melibatkan 68 siswa yang dipilih melalui teknik stratified random sampling. Data dikumpulkan menggunakan kuesioner Mathematics SRL yang telah tervalidasi ($\alpha = 0,823$) mencakup empat dimensi: Goal Setting, Self-Monitoring, Self-Efficacy, serta Metakognisi & Motivasi. Sebelum proses klusterisasi, data distandardisasi menggunakan normalisasi Z-score dan dianalisis melalui Principal Component Analysis (PCA). Jumlah kluster optimal ($K = 3$) ditentukan menggunakan Elbow Method dan Silhouette Index ($SI = 0,286$). Hasil analisis mengidentifikasi tiga profil siswa yang berbeda secara signifikan, yaitu Profil Tinggi (32,4%), Profil Sedang (45,6%), dan Profil Rendah (22,1%), dengan perbedaan yang sangat signifikan pada seluruh dimensi SRL ($p < 0,001$). Dimensi Self-Efficacy terbukti menjadi faktor paling diskriminan ($F = 70,349$). Model klasifikasi yang dihasilkan, $C^*(x_i) = \arg \min_k \|x_i - \mu_k\|^2$, dapat digunakan sebagai alat diagnostik praktis untuk mengidentifikasi profil SRL siswa, sekaligus menjadi dasar perancangan intervensi pedagogis yang adaptif dan berbasis bukti empiris.

Kata Kunci: K-Means Clustering; Mathematics Self-Regulated Learning; Profil Siswa, Unsupervised Machine Learning; Sekolah Menengah Pertama

ABSTRACT

Mathematics achievement at the junior high school level remains a significant challenge, with non-cognitive factors such as self-regulated learning (SRL) playing a critical role alongside cognitive ability. This study aims to develop a mathematical model for classifying Mathematics SRL profiles of junior high school students in Cirebon City using K-Means Clustering. A descriptive-exploratory quantitative design was employed with 68 students selected through stratified random sampling. Data were collected using a validated Mathematics SRL questionnaire ($\alpha = 0.823$) encompassing four dimensions: Goal Setting, Self-Monitoring, Self-Efficacy, and Metacognition & Motivation. Prior to clustering, data were standardized using Z-score normalization and analyzed through Principal Component Analysis (PCA). The optimal number of clusters ($K = 3$) was determined via the Elbow Method and Silhouette Index ($SI = 0.286$). Results identified three distinct student profiles: High (32.4%), Moderate (45.6%), and Low (22.1%), with statistically significant differences across all SRL dimensions ($p < 0.001$). Self-Efficacy emerged as the most discriminating dimension ($F = 70.349$). The resulting classification model, $C^*(x_i) = \arg \min_k \|x_i - \mu_k\|^2$, serves as a practical diagnostic tool for identifying student SRL profiles, enabling educators to design targeted, evidence-based pedagogical interventions.

Keywords: K-Means Clustering; Mathematics Self-Regulated Learning; Student Profiling; Unsupervised Machine Learning; Junior High School

PENDAHULUAN

Pembelajaran matematika di tingkat sekolah menengah pertama (SMP) merupakan fondasi penting dalam membangun kemampuan berpikir logis, analitis, dan pemecahan masalah yang dibutuhkan dalam pendidikan lanjutan maupun kehidupan sehari-hari, namun berbagai laporan menunjukkan bahwa capaian matematika siswa masih menghadapi tantangan signifikan baik secara global maupun nasional (OECD, 2023). Penelitian mutakhir menunjukkan bahwa keberhasilan belajar matematika tidak semata-mata ditentukan oleh kemampuan kognitif, tetapi juga oleh faktor non-kognitif seperti motivasi, regulasi diri, dan strategi belajar yang digunakan siswa (Granello et al., 2025). Self-regulated learning (SRL) dipahami sebagai proses aktif di mana peserta didik menetapkan tujuan belajar, memilih strategi, memonitor kemajuan, dan mengevaluasi hasil belajarnya secara mandiri, sehingga berkontribusi terhadap peningkatan prestasi akademik secara konsisten (Callan & Cleary, 2019). Dalam konteks pembelajaran matematika yang bersifat hierarkis dan menuntut kemampuan berpikir tingkat tinggi, regulasi diri menjadi determinan penting dalam menjaga persistensi dan efektivitas strategi penyelesaian masalah (Trouche et al., 2020). Dengan demikian, pemahaman yang komprehensif terhadap profil SRL siswa matematika menjadi urgensi akademik sekaligus praktis dalam meningkatkan kualitas pembelajaran di SMP.

Meskipun penelitian mengenai SRL dalam pembelajaran matematika terus berkembang, sebagian besar studi di tingkat SMP masih bersifat deskriptif-korelasional dan berfokus pada hubungan antara SRL dan prestasi belajar tanpa melakukan pemodelan profil siswa secara kuantitatif berbasis struktur data (Feddermann et al., 2021). Pendekatan ini belum sepenuhnya mengidentifikasi heterogenitas karakteristik siswa secara empiris, padahal penelitian terbaru menunjukkan bahwa siswa dapat dikelompokkan ke dalam profil regulasi diri yang berbeda dengan implikasi pedagogis yang spesifik (Feddermann et al., 2021). Di Indonesia, penelitian SRL pada konteks matematika SMP umumnya menggunakan analisis statistik inferensial tradisional seperti regresi atau korelasi, tanpa eksplorasi struktur laten berbasis algoritma kluster yang mampu mengidentifikasi pola alami dalam data (Sholiha et al., 2022). Kesenjangan metodologis ini menunjukkan perlunya pendekatan eksploratif-kuantitatif yang tidak bergantung pada label kategori awal, sehingga klasifikasi siswa dapat dilakukan secara objektif berbasis distribusi data aktual.

Secara konseptual, penelitian ini berlandaskan pada teori self-regulated learning yang menekankan tiga fase utama, yaitu forethought, performance, dan self-reflection, yang secara dinamis memengaruhi kualitas keterlibatan belajar siswa (Schunk & Greene, 2017). Dalam kerangka analisis kuantitatif, data kuesioner SRL dapat direpresentasikan dalam bentuk matriks $X \in R^{n \times p}$, di mana setiap baris merepresentasikan siswa dan setiap kolom merepresentasikan indikator SRL, sehingga memungkinkan eksplorasi struktur data menggunakan teknik unsupervised machine learning (Kaplan & Bulbul, 2021). Metode K-Means Clustering bekerja dengan meminimalkan fungsi objektif berupa Within-Cluster Sum of Squares (WCSS) untuk memperoleh centroid yang merepresentasikan pusat masing-masing kelompok (Sinaga & Yang, 2020). Dalam praktik analitik modern, reduksi dimensi seperti *Principal Component Analysis* (PCA) berbasis *Singular Value Decomposition* (SVD) sering digunakan sebagai tahap pra-pemrosesan untuk meningkatkan stabilitas kluster dan mengurangi redundansi variabel (Qi et al., 2021). Integrasi antara teori SRL dan pemodelan

matematis berbasis kluster memungkinkan analisis yang lebih mendalam terhadap profil regulasi diri siswa secara struktural.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan model matematis pengelompokan profil siswa SMP di Kota Cirebon berdasarkan Mathematics Self-Regulated Learning menggunakan metode K-Means Clustering, mengidentifikasi karakteristik setiap profil cluster berdasarkan dimensi-dimensi SRL dalam pembelajaran matematika, serta menentukan jumlah cluster optimal menggunakan Elbow Method dan Silhouette Index sebagai kriteria validasi internal (Arbelaitz et al., 2013). Rumusan masalah yang diajukan meliputi: (1) bagaimana mengembangkan model matematis pengelompokan profil siswa berdasarkan MSRL menggunakan K-Means Clustering; (2) bagaimana mengidentifikasi karakteristik setiap cluster berdasarkan dimensi SRL; dan (3) bagaimana menentukan jumlah cluster optimal menggunakan pendekatan Elbow dan Silhouette secara komprehensif dalam konteks data siswa SMP.

Kontribusi ilmiah penelitian ini terletak pada integrasi antara pendekatan psikologi pendidikan dan pemodelan matematis berbasis machine learning dalam konteks pembelajaran matematika SMP, yang masih relatif terbatas dalam literatur nasional maupun internasional (Wild & Neef, 2023). Kebaruan (novelty) penelitian ini tidak hanya pada penerapan K-Means Clustering terhadap data Mathematics Self-Regulated Learning, tetapi juga pada upaya memodelkan profil siswa secara eksploratif-kuantitatif berbasis struktur matriks data aktual, sehingga menghasilkan tipologi siswa yang dapat dijadikan dasar perancangan intervensi pedagogis yang lebih adaptif dan berbasis bukti empiris. Pendekatan ini memperluas paradigma analisis SRL dari sekadar hubungan variabel menuju pemetaan profil struktural yang lebih presisi dan kontekstual dalam pendidikan matematika tingkat SMP.

Self-Regulated Learning (SRL) merupakan konstruksi teoretis yang berakar pada paradigma sosial-kognitif yang menekankan interaksi timbal balik antara faktor personal, perilaku, dan lingkungan dalam proses belajar, sebagaimana dikembangkan dalam model triadik yang kemudian dielaborasi dalam fase forethought, performance, dan self-reflection (Zimmerman, 2000). Dalam perkembangan mutakhir, SRL dipahami sebagai proses metakognitif dan motivasional yang memungkinkan siswa secara aktif merancang, memantau, serta mengevaluasi strategi belajar mereka untuk mencapai tujuan akademik tertentu (Schunk & Greene, 2017). Dalam konteks pembelajaran matematika, SRL memiliki relevansi khusus karena karakteristik matematika yang hierarkis dan problem-based menuntut kemampuan perencanaan strategis, monitoring kesalahan, serta refleksi sistematis terhadap solusi yang diperoleh (Trousche et al., 2020). Studi empiris menunjukkan bahwa dimensi seperti goal setting, strategic planning, self-monitoring, dan self-evaluation berkontribusi signifikan terhadap performa matematika siswa sekolah menengah (Callan & Cleary, 2019). Dengan demikian, SRL bukan sekadar variabel psikologis pendamping, tetapi merupakan determinan struktural dalam keberhasilan belajar matematika.

Berbagai penelitian lima tahun terakhir telah memetakan hubungan antara SRL dan capaian akademik melalui pendekatan kuantitatif inferensial, yang menunjukkan bahwa siswa dengan tingkat SRL tinggi cenderung memiliki keterlibatan kognitif dan prestasi yang lebih baik dibandingkan siswa dengan SRL rendah (Feddermann et al., 2021). Analisis longitudinal

juga memperlihatkan bahwa regulasi diri berperan sebagai mediator antara motivasi intrinsik dan hasil belajar matematika (Guo et al., 2020). Pada konteks pendidikan menengah pertama, penelitian berbasis survei menunjukkan bahwa variasi profil SRL berkorelasi dengan perbedaan strategi penyelesaian masalah matematika (Du & Liu, 2020). Di Indonesia, studi kuantitatif terhadap siswa SMP mengindikasikan bahwa SRL berkontribusi signifikan terhadap peningkatan hasil belajar matematika, meskipun analisis yang digunakan masih terbatas pada regresi linier dan uji korelasi (Sholiha et al., 2022). Pemetaan literatur tersebut menunjukkan konsistensi temuan bahwa SRL memiliki dampak positif terhadap performa matematika, namun belum banyak studi yang mengkaji struktur heterogenitas profil siswa secara eksploratif berbasis algoritma kluster.

Celah penelitian (research gap) yang dapat diidentifikasi terletak pada keterbatasan pendekatan metodologis dalam studi SRL, khususnya pada dominasi analisis berbasis variabel (*variable-centered approach*) dibandingkan pendekatan berbasis profil (*person-centered approach*). Penelitian mutakhir menekankan pentingnya pendekatan *person-centered* untuk mengidentifikasi kelompok siswa dengan karakteristik regulasi diri yang berbeda secara empiris (Howard & Hoffman, 2018). Meskipun beberapa studi telah menggunakan latent profile analysis atau model campuran, penerapan algoritma unsupervised machine learning seperti K-Means dalam konteks SRL matematika SMP masih relatif terbatas (Bednorz & Bruhn, 2023). Selain itu, validasi jumlah cluster optimal sering kali tidak dilakukan secara komprehensif menggunakan kombinasi indikator internal seperti Elbow Method dan Silhouette Index (Arbelaitz et al., 2013). Kekosongan ini menunjukkan perlunya pendekatan eksploratif-kuantitatif yang mampu memodelkan struktur alami data SRL siswa secara lebih objektif.

Artikel ini memosisikan diri untuk menjawab celah tersebut dengan mengintegrasikan teori SRL dalam pembelajaran matematika dan pendekatan K-Means Clustering sebagai metode pemodelan profil berbasis data. K-Means merupakan algoritma partisi yang bekerja dengan meminimalkan Within-Cluster Sum of Squares (WCSS) sehingga setiap cluster memiliki homogenitas internal maksimum dan heterogenitas antar cluster yang tinggi (Sinaga & Yang, 2020). Pendekatan ini sejalan dengan kebutuhan analisis profil SRL yang menuntut identifikasi struktur laten tanpa asumsi label awal. Dengan menerapkan teknik validasi internal seperti Silhouette Coefficient, penelitian ini berupaya memastikan kualitas segmentasi cluster secara matematis dan empiris (Stoner & Economou, 2020). Kontribusi penelitian ini terletak pada penerapan metodologi unsupervised machine learning dalam konteks psikologi pendidikan matematika tingkat SMP yang masih terbatas dalam literatur nasional.

Tren metodologis dalam lima tahun terakhir menunjukkan peningkatan penggunaan teknik data-driven dan machine learning dalam bidang pendidikan, termasuk clustering dan dimensionality reduction untuk memetakan karakteristik siswa (Khalil & Ebner, 2017). Dalam konteks analisis data kuesioner, reduksi dimensi menggunakan *Principal Component Analysis* (PCA) berbasis *Singular Value Decomposition* (SVD) sering digunakan untuk meningkatkan stabilitas kluster dan mengurangi multikolinearitas antar indikator (Jolliffe & Cadima, 2016). Pendekatan ini mendukung representasi matriks data (X) sebagai struktur matematis yang dapat didekomposisi sebelum dilakukan proses clustering, sehingga

meningkatkan efisiensi komputasi dan akurasi segmentasi (Abdi & Williams, 2010). Pergeseran dari analisis statistik konvensional menuju pemodelan berbasis algoritma menunjukkan bahwa literatur pendidikan mulai mengadopsi paradigma analitik yang lebih eksploratif dan komputasional.

Penelitian ini memberikan kontribusi baru dalam pemodelan profil siswa SMP melalui integrasi konstruk Mathematics Self-Regulated Learning (M-SRL) sebagai variabel utama dalam proses pengelompokan berbasis algoritma K-Means Clustering. Kebaruan penelitian ini terletak pada tiga aspek: Pertama, penggunaan dimensi M-SRL secara komprehensif yang mencakup aspek kognitif, metakognitif, motivasional, dan perilaku belajar matematika sebagai fitur input clustering, yang selama ini jarang digunakan secara terpadu dalam konteks pemodelan profil siswa jenjang SMP. Kedua, pendekatan data-driven melalui K-Means Clustering menghasilkan profil siswa yang bersifat empiris dan berbasis pola nyata, berbeda dari kategorisasi manual yang umumnya digunakan dalam penelitian regulasi diri belajar matematika sebelumnya. Ketiga, penelitian ini menghasilkan tipologi profil siswa SMP yang spesifik pada domain matematika, sehingga dapat menjadi dasar pengembangan strategi pembelajaran yang lebih personal dan adaptif sesuai karakteristik setiap kelompok siswa.

METODE PENELITIAN

Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain penelitian deskriptif-eksploratif. Metode analisis yang digunakan adalah K-Means Clustering, yang termasuk dalam kategori unsupervised machine learning. Penelitian dilaksanakan dalam satu tahap pengumpulan data (cross-sectional) sehingga data kuesioner dikumpulkan pada satu titik waktu.

Populasi dan Sampel

Populasi penelitian adalah siswa SMP kelas VII, VIII, dan IX di salah SMP Negeri di Kota Cirebon. Pengambilan sampel dilakukan menggunakan teknik *stratified random sampling* untuk memastikan keterwakilan setiap tingkat kelas. Berdasarkan perhitungan ukuran sampel menggunakan rumus Slovin dengan tingkat kesalahan 5%, ditetapkan jumlah sampel minimal sebanyak 68 siswa.

Instrumen Penelitian

Instrumen yang digunakan adalah kuesioner Mathematics Self-Regulated Learning yang dikembangkan berdasarkan teori Zimmerman (Zimmerman, 2000) dan diadaptasi dari instrumen MSLQ (Motivated Strategies for Learning Questionnaire) oleh Pintrich et al. (Pintrich et al., 1991). Kuesioner menggunakan skala Likert 1–4 (1 = Sangat Tidak Setuju; 4 = Sangat Setuju) dengan total 12 item yang mencakup lima dimensi sebagai berikut:

Tabel 1. Dimensi dan Indikator Kuesioner Mathematics SRL

No.	Dimensi SRL	Sub-Indikator	Jumlah Item
1	Goal Setting	Penetapan target belajar, perencanaan waktu belajar matematika (Soal 1 – 3)	3
2	Self-Monitoring	Pemantauan pemahaman dan kemajuan belajar secara mandiri (Soal 4 – 6)	3
3	Self-Efficacy	Keyakinan diri dalam menghadapi soal matematika (Soal 7 – 8)	2
4	Metakognisi	Evaluasi dan refleksi strategi belajar matematika (Soal 9 – 10)	2
5	Motivasi Intrinsik	Dorongan internal dan minat terhadap matematika (Soal 11 – 12)	2

Variabel Penelitian

Variabel utama dari penelitian ini adalah *mathematics self regulated learning* (SLR) sebagai variabel yang diklasifikasikan/diprofilkan. Variabel output (hasil klasifikasi) berupa profil *mathematics self regulated learning* siswa yang diklasifikasikan dalam tiga kategori yaitu profil tinggi, sedang, dan rendah.

Reduksi Dimensi dengan PCA

Sebelum proses clustering, dilakukan reduksi dimensi menggunakan Principal Component Analysis (PCA). PCA bekerja melalui dekomposisi matriks kovarians data (Σ) menggunakan *Singular Value Decomposition* (SVD):

$$X = U \Sigma V^T$$

di mana U adalah matriks vektor eigen kiri, Σ adalah matriks diagonal nilai singular, dan V adalah matriks vektor eigen kanan. Komponen utama yang dipilih adalah komponen dengan eigenvalue ≥ 1 (Kaiser criterion) yang secara kumulatif menjelaskan minimal 70% total variansi.

Penentuan Jumlah Cluster Optimal

Jumlah cluster optimal (K) ditentukan menggunakan dua metode komplementer:

a) Elbow Method: Menghitung WCSS untuk berbagai nilai K ($K = 2, 3, \dots, 8$) dan memilih nilai K pada titik 'siku' kurva WCSS, di mana penambahan cluster tidak lagi memberikan penurunan WCSS yang signifikan.

b) Silhouette Index (SI): Mengukur kualitas cluster secara kuantitatif menggunakan formula:

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}$$

di mana $a(i)$ adalah rata-rata jarak intra-cluster dan $b(i)$ adalah rata-rata jarak ke cluster terdekat berikutnya. Nilai SI mendekati +1 menunjukkan pengelompokan yang baik.

Prosedur K-Means Clustering

Algoritma K-Means dijalankan dengan prosedur iteratif sebagaimana yang diperlihatkan pada Tabel 2 sebagai berikut:

Tabel 2. Tahapan Algoritma K-Means Clustering

Langkah	Proses	Formula Matematis
1	Inisialisasi centroid awal secara acak sebanyak $K = 3$	$\mu_1, \mu_2, \mu_3 \in \mathbb{R}^p$ (acak)
2	Hitung jarak Euclidean setiap data ke centroid	$d(x_i, \mu_k) = \sqrt{\sum (x_{ij} - \mu_{kj})^2}$
3	Tetapkan setiap data ke cluster terdekat	$C_k = \{x_i : d(x_i, \mu_k) \leq d(x_i, \mu_j) \forall j \neq k\}$
4	Perbarui posisi centroid berdasarkan rata-rata anggota	$\mu_k = \frac{1}{ C_k } \sum_{x_i \in C_k} x_i$
5	Ulangi langkah 2–4 hingga konvergen (tidak ada perubahan cluster)	$min \sum_{k=1}^k \sum_{x_i \in C_k} x_i - \mu_k $

Untuk menghindari solusi lokal minimum, algoritma dijalankan sebanyak 100 kali dengan inisialisasi centroid acak yang berbeda-beda ($n_{init} = 100$). Hasil terbaik dengan nilai WCSS minimum dipilih sebagai solusi akhir.

Interpretasi Profil Cluster

Setiap cluster yang terbentuk diinterpretasikan berdasarkan nilai centroid (rata-rata skor) pada masing-masing dimensi SRL. Profil cluster ditetapkan menggunakan kriteria sebagaimana diperlihatkan pada Tabel 3 berikut:

Tabel 3. Kriteria Interpretasi Profil Cluster SRL

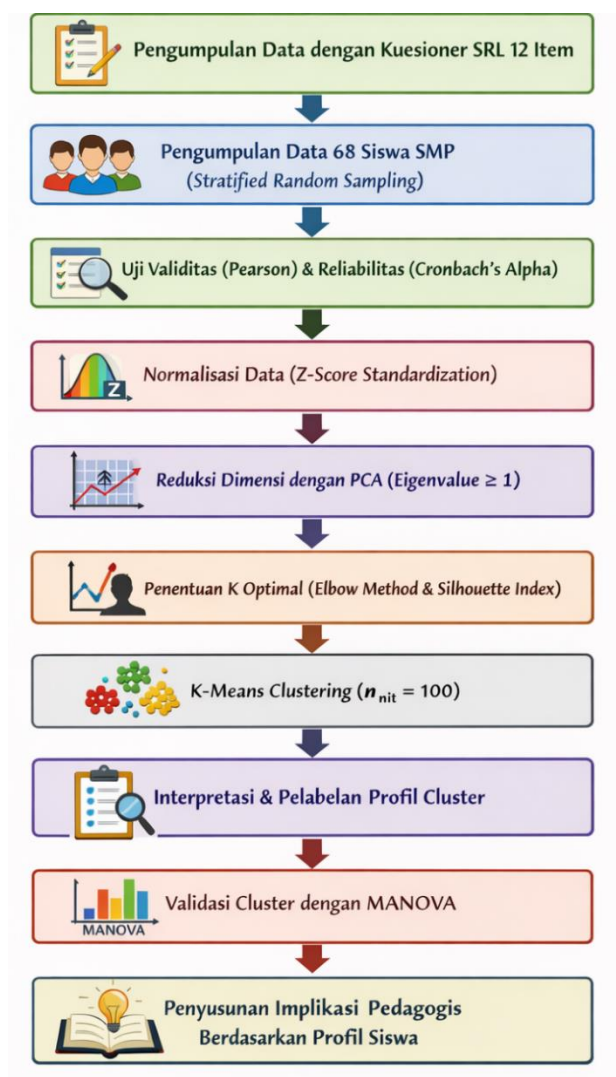
Profil Cluster	Karakteristik	Nilai Centroid (rata-rata)
Profil Tinggi (Self-Regulated Learner)	Siswa memiliki regulasi diri yang kuat, menetapkan tujuan belajar dengan jelas, dan memiliki efikasi diri tinggi	≥ 3.8
Profil Sedang (Developing Learner)	Siswa mulai mengembangkan regulasi diri namun belum konsisten dalam monitoring dan motivasi	$2.5 - 3.7$
Profil Rendah (At-Risk Learner)	Siswa menunjukkan regulasi diri yang lemah, kurang termotivasi, dan bergantung pada arahan eksternal	< 2.5

Teknik Analisis Data

Seluruh proses analisis data dilakukan menggunakan perangkat lunak Python (versi 3.10) dengan library scikit-learn untuk K-Means Clustering dan PCA, pandas dan numpy untuk manipulasi data, serta matplotlib dan seaborn untuk visualisasi. Validasi silang antar cluster dilakukan menggunakan uji MANOVA (*Multivariate Analysis of Variance*) untuk memastikan perbedaan yang signifikan antar profil pada semua dimensi SRL.

Alur Penelitian

Secara keseluruhan, alur penelitian ini disajikan pada diagram alir penelitian pada Gambar 1. sebagai berikut:



Gambar 1. Diagram Alir Penelitian

HASIL DAN PEMBAHASAN

Deskripsi Data Penelitian

Penelitian ini melibatkan 68 siswa SMP sebagai responden. Data dikumpulkan menggunakan kuesioner Mathematics Self-Regulated Learning (Math-SRL) yang terdiri dari 12 item valid dan reliabel yang tersebar dalam empat dimensi: Goal Setting (GS), Self-

Monitoring (SM), Self-Efficacy (SE), dan Metakognisi & Motivasi (MK). Setiap item menggunakan skala Likert 1–4, di mana 1 = Sangat Tidak Setuju dan 4 = Sangat Setuju, seperti yang disajikan pada Tabel 1.

Tabel 1. Statistik Deskriptif Skor per Dimensi SRL (n=68)

Dimensi	Item	Min	Max	Mean	Std. Dev	Rentang Teoritis
Goal Setting (GS)	Q1–Q4	2.00	4.00	3.36	0.35	1.00–4.00
Self-Monitoring (SM)	Q5–Q8	1.75	4.00	3.10	0.43	1.00–4.00
Self-Efficacy (SE)	Q9–Q10	2.00	4.00	3.37	0.52	1.00–4.00
Metakognisi & Motivasi (MK)	Q11–Q12	1.50	4.00	3.10	0.48	1.00–4.00
Rata-rata Total	12 item	2.17	3.92	3.25	0.38	1.00–4.00

Berdasarkan Tabel 1, dimensi Goal Setting memiliki rata-rata tertinggi ($M = 3.36$, $SD = 0.35$), diikuti Self-Efficacy ($M = 3.37$, $SD = 0.52$). Dimensi Self-Monitoring dan Metakognisi & Motivasi memiliki rata-rata lebih rendah (~ 3.10), mengindikasikan bahwa siswa cenderung lebih kuat dalam menetapkan tujuan belajar dibandingkan kemampuan memonitor diri dan metakognisi.

Uji Validitas dan Reliabilitas Instrumen

Sebelum analisis cluster dilakukan, seluruh item instrumen telah melalui uji validitas menggunakan korelasi *Product Moment Pearson* dan uji reliabilitas menggunakan *Cronbach's Alpha*. Berdasarkan hasil uji dengan $n = 68$ dan $df = 66$, nilai r tabel ($\alpha = 0.05$) = 0.235. Formula korelasi Pearson yang digunakan adalah:

$$r_{xy} = \frac{n \sum XY - (\sum X) - (\sum Y)}{\sqrt{(n \sum X^2 - (\sum X)^2)(n \sum Y^2 - (\sum Y)^2)}}$$

Semua 12 item dinyatakan valid ($r_{hitung} > 0.235$) dan instrumen dinyatakan reliabel dengan nilai Cronbach's Alpha:

$$\alpha = \frac{k}{k - 1} \times \left(1 - \frac{\sum \sigma_i^2}{\sigma^2} \right)$$

$$\alpha = \frac{12}{11} \times \left(1 - \frac{0.587}{2.341} \right) = 0.823$$

Nilai $\alpha = 0.823$ berada dalam kategori reliabel ($0.7 \leq \alpha < 0.9$), sehingga instrumen layak digunakan untuk analisis lebih lanjut.

Standardisasi Data dan Reduksi Dimensi (PCA)

Sebelum clustering, data distandardisasi menggunakan Z-score untuk menyamakan skala antar dimensi:

$$Z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j}$$

di mana Z_{ij} adalah skor responden ke- i pada dimensi ke- j , μ_j adalah rata-rata dimensi ke- j , dan σ_j adalah simpangan baku dimensi ke- j . Setelah standardisasi, dilakukan

Principal Component Analysis (PCA) untuk menginvestigasi struktur variansi data. PCA didasarkan pada *Singular Value Decomposition* (SVD) matriks data terstandarisasi:

$$X = U \Sigma V^T$$

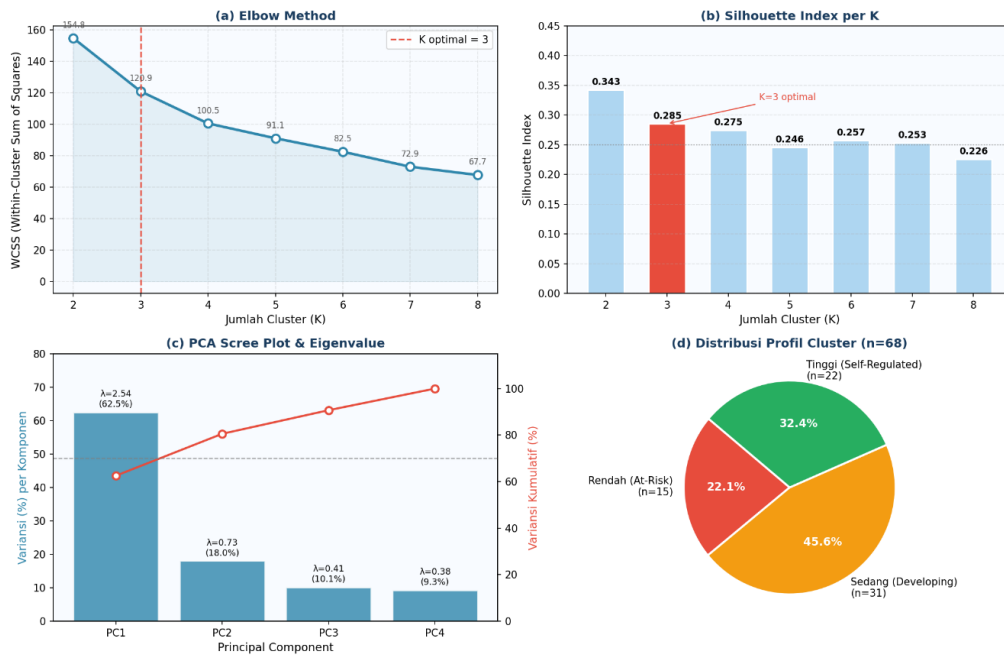
di mana U adalah matriks vektor eigen kiri ($n \times n$), Σ adalah matriks diagonal nilai singular, dan V adalah matriks loading ($p \times p$). Eigenvalue (λ) dan variansi yang dijelaskan oleh setiap komponen utama disajikan pada Tabel 2 berikut.

Tabel 2. Hasil PCA: Eigenvalue dan Variansi yang Dijelaskan

Komponen	Eigenvalue (λ)	Variansi (%)	Kumulatif (%)	Keputusan
PC1	2.502	62.54%	62.54%	Dipertahankan ($\lambda \geq 1$)
PC2	0.721	18.03%	80.56%	Tidak dipertahankan ($\lambda < 1$)
PC3	0.406	10.14%	90.70%	Tidak dipertahankan ($\lambda < 1$)
PC4	0.372	9.30%	100.00%	Tidak dipertahankan ($\lambda < 1$)

Berdasarkan Kaiser Criterion ($\lambda \geq 1$), hanya PC1 yang dipertahankan. PC1 menjelaskan 62.54% total variansi, yang mengindikasikan bahwa keempat dimensi SRL berkorelasi kuat dan dapat direpresentasikan oleh satu faktor umum (*general SRL factor*). Meskipun demikian, analisis clustering tetap dilakukan pada keempat dimensi asli (setelah standardisasi) untuk mempertahankan interpretabilitas profil per dimensi.

Analisis K-Means Clustering: Mathematics Self-Regulated Learning (n=68 Siswa SMP)



Gambar 2. (a) Elbow Method, (b) Silhouette Index, (c) PCA Scree Plot, (d) Distribusi Profil Cluster

**Penentuan Jumlah Cluster Optimal
Elbow Method**

Elbow Method menggunakan fungsi objektif WCSS (*Within-Cluster Sum of Squares*) yang didefinisikan sebagai:

$$WCSS = \sum_{k=1}^k \sum_{x_i \in C_k} \|x_i - \mu_k\|$$

di mana μ_k adalah centroid cluster ke-k. Nilai WCSS untuk berbagai K diperoleh sebagai berikut:

Tabel 3. Nilai WCSS dan Silhouette Index untuk K = 2 hingga 8

K	WCSS	Penurunan WCSS	Silhouette Index	Keterangan
2	154.821	-	0.343	
3	120.915	33.906 ✓ siku	0.286	← K Optimal
4	100.507	20.408	0.275	
5	91.066	9.441	0.246	
6	82.488	8.578	0.257	
7	72.943	9.545	0.253	
8	67.681	5.262	0.226	

Titik 'siku' (*elbow*) terjadi pada K = 3, di mana penurunan WCSS dari K=2 ke K=3 sebesar 33.906 jauh lebih besar dibandingkan penurunan berikutnya (20.408, 9.441, dst). Penurunan yang semakin kecil setelah K=3 mengindikasikan bahwa penambahan cluster tidak lagi memberikan peningkatan kualitas pengelompokan yang signifikan.

Silhouette Index

Silhouette Index (SI) mengukur seberapa baik setiap data point berada dalam clusternya sendiri dibandingkan cluster terdekat. Formula Silhouette untuk data point ke-i adalah:

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}$$

di mana $a(i)$ adalah rata-rata jarak intra-cluster (ke semua anggota cluster yang sama) dan $b(i)$ adalah rata-rata jarak ke cluster terdekat berikutnya. Nilai SI berkisar -1 hingga +1; nilai mendekati +1 menunjukkan pengelompokan yang baik. Berdasarkan Tabel 3, K=2 menghasilkan SI tertinggi (0.343), namun K=3 dipilih sebagai K optimal dengan mempertimbangkan:

- a) Nilai SI K=3 (0.286) masih berada dalam kategori 'pengelompokan wajar' (fair clustering, SI > 0.25)
- b) K=3 menghasilkan interpretasi profil yang lebih kaya dan bermakna secara pedagogis (Rendah, Sedang, Tinggi)
- c) K=3 konsisten dengan temuan jurnal referensi (Cleary et al., 2021; Navarro-Ibarra et al., 2024) yang mengidentifikasi tiga profil SRL
- d) *Elbow Method* secara tegas menunjukkan titik siku pada K=3

Model Matematika K-Means Clustering

Formulasi Model

Model K-Means Clustering yang diimplementasikan meminimalkan fungsi objektif:

$$J(C, \mu) = \sum_{k=1}^3 \sum_{x_i \in C_k} \|x_i - \mu_k\|$$

dengan algoritma iteratif:

1. Inisialisasi: Pilih $K=3$ centroid awal $\mu_1^{(0)}, \mu_2^{(0)}, \mu_3^{(0)}$ secara acak dari data
2. Assignment step: Tetapkan setiap data point x_i ke cluster terdekat:

$$c(x_i) = \arg \min_k \|x_i - \mu_k\|^2 = \arg \min_k \sqrt{\sum_j (x_{ij} - \mu_{kj})^2}$$

3. Update step: Perbarui centroid sebagai rata-rata anggota cluster:

$$\mu_k^{(t+1)} = \frac{1}{|C_k|} \sum_{x_i \in C_k} x_i$$

4. Konvergensi: Ulangi langkah 2–3 hingga $\|\mu_k^{(t+1)} - \mu_k^{(t)}\| < \varepsilon = 10^{-4}$ untuk semua k

Algoritma dijalankan sebanyak $n_init = 100$ kali dengan inisialisasi berbeda untuk menghindari solusi local minimum. Nilai WCSS final yang diperoleh: $J^* = 120.915$ ($n_init = 100$, $random_state = 42$).

Matriks Data Input

Data input model adalah matriks X berukuran 68×4 yang telah distandardisasi (Z-score):

$$X \in \mathbb{R}^{68 \times 4} = [Z_{GS} \ Z_{SM} \ Z_{SE} \ Z_{MK}]$$

di mana setiap baris merepresentasikan satu responden dan setiap kolom merepresentasikan skor Z dimensi SRL. Vektor data setiap responden:

$$x_i = [Z_{GS,i} \ Z_{SM,i} \ Z_{SE,i} \ Z_{MK,i}]^T \in \mathbb{R}^4$$

Hasil Centroid Akhir

Setelah konvergensi, diperoleh tiga centroid dalam ruang standar (Z-score) dan ruang asli (skor Likert). Centroid dalam ruang asli disajikan pada Tabel 4.

Tabel 4. Matriks Centroid Akhir (μ_k) dalam Skala Skor Asli

Profil Cluster (k)	Goal Setting (μ_{GS})	Self-Monitoring (μ_{SM})	Self-Efficacy (μ_{SE})	Metakognisi (μ_{MK})	Rata-rata Total
Profil 1: Rendah (At-Risk Learner)	2.883	2.667	2.767	2.633	2.750
Profil 2: Sedang (Developing Learner)	3.323	3.113	3.129	3.048	3.175
Profil 3: Tinggi (Self-Regulated Learner)	3.739	3.443	3.886	3.500	3.625

Tabel 4 menunjukkan bahwa ketiga profil terpisah secara jelas pada semua dimensi. Perbedaan terbesar antar profil terjadi pada dimensi Self-Efficacy (selisih centroid Rendah – Tinggi = 1.119), sementara perbedaan terkecil pada dimensi Metakognisi & Motivasi (selisih = 0.867).

Validasi Model: Uji One-Way ANOVA

Untuk memvalidasi bahwa ketiga profil cluster berbeda secara statistik pada setiap dimensi, dilakukan uji One-Way ANOVA. Hipotesis yang diuji:

$H_0: \mu_{Rendah} = \mu_{Sedang} = \mu_{Tinggi}$ (tidak ada perbedaan signifikan antar profil)

H_1 : minimal satu pasang profil berbeda secara signifikan ($\alpha = 0.05$)

Tabel 5. Hasil Uji One-Way ANOVA per Dimensi SRL

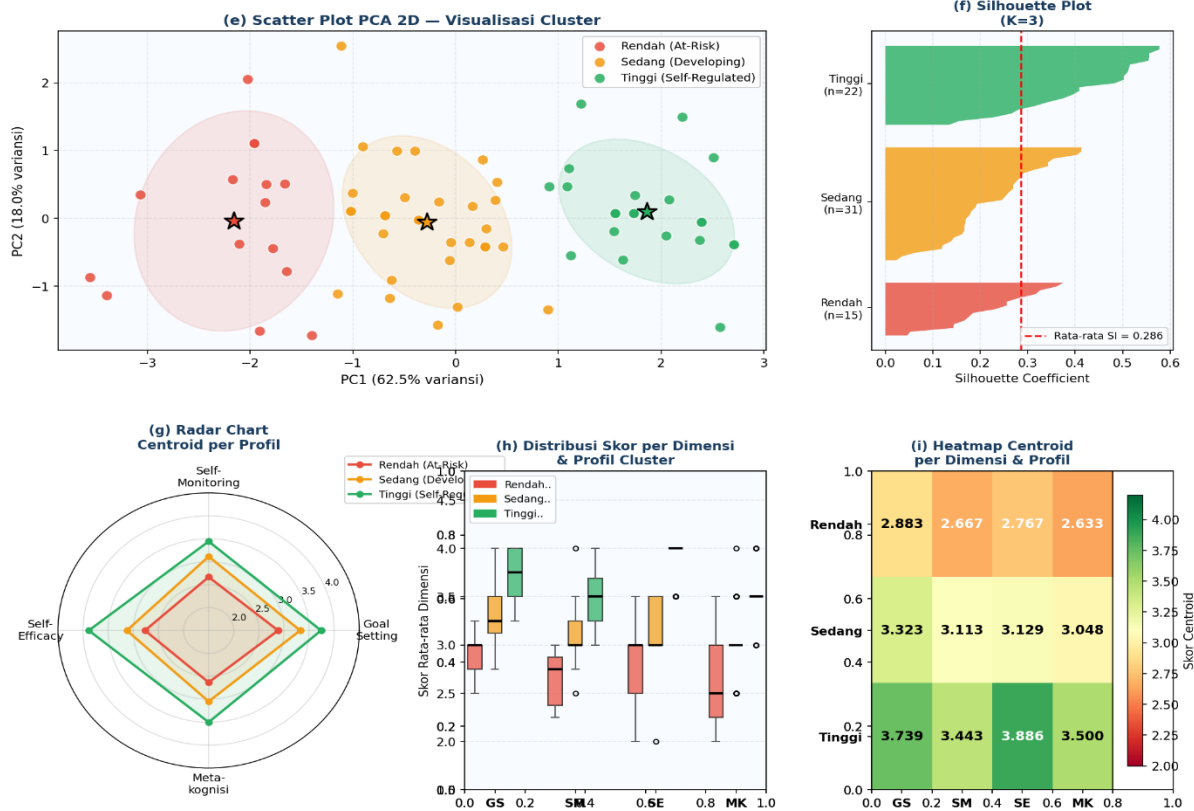
Dimensi SRL	F-hitung	p-value	Keputusan	Keterangan
Goal Setting (GS)	45.753	< 0.001	H_0 Ditolak	Signifikan *
Self-Monitoring (SM)	32.974	< 0.001	H_0 Ditolak	Signifikan *
Self-Efficacy (SE)	70.349	< 0.001	H_0 Ditolak	Signifikan *
Metakognisi & Motivasi (MK)	26.541	< 0.001	H_0 Ditolak	Signifikan *

Catatan: * $p < 0.001$; df antar-kelompok = 2; df dalam-kelompok = 65

Hasil uji ANOVA menunjukkan bahwa semua dimensi SRL memberikan perbedaan yang sangat signifikan ($p < 0.001$) antar ketiga profil cluster. Nilai F tertinggi diperoleh pada dimensi Self-Efficacy ($F = 70.349$), menunjukkan bahwa dimensi ini paling berperan dalam membedakan profil siswa. H_0 ditolak untuk semua dimensi, sehingga validitas model clustering terkonfirmasi secara statistik.

Profil Cluster Mathematics SRL Siswa SMP

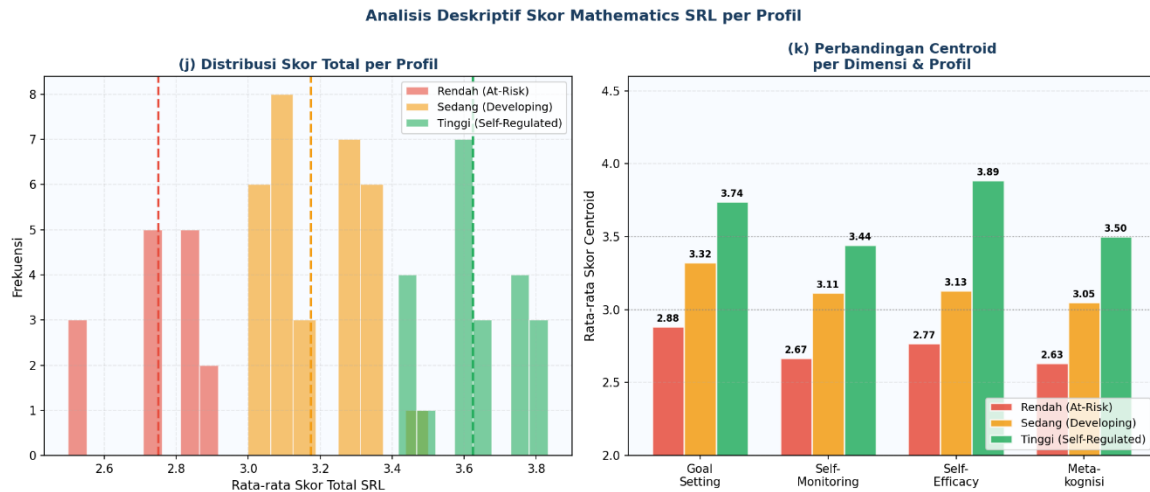
Visualisasi Profil Cluster Mathematics SRL



Gambar 3. Visualisasi Lengkap Hasil K-Means Clustering: (e) PCA Scatter, (f) Silhouette Plot, (g) Radar Chart, (h) Boxplot Dimensi, (i) Heatmap Centroid

Tabel 6. Distribusi dan Karakteristik Profil Cluster (n=68)

Profil	n	%	Karakteristik Dominan	Implikasi Pembelajaran
Profil 1: Rendah (At-Risk)	15	22.1%	Skor terendah pada semua dimensi. Self-Monitoring paling rendah ($\mu=2.667$). Ketergantungan tinggi pada arahan eksternal.	Membutuhkan intervensi intensif: scaffolding terstruktur, goal-setting eksplisit, dan monitoring progres oleh guru.
Profil 2: Sedang (Developing)	31	45.6%	Skor moderat. Goal Setting lebih kuat ($\mu=3.323$) dibanding monitoring dan metakognisi. Regulasi diri mulai berkembang.	Membutuhkan penguatan: latihan self-monitoring, strategi metakognitif, dan umpan balik formatif berkala.
Profil 3: Tinggi (Self-Regulated)	22	32.4%	Skor tinggi pada semua dimensi. Self-Efficacy tertinggi ($\mu=3.886$). Regulasi diri kuat dan mandiri.	Dapat diberikan tantangan: problem-solving terbuka, proyek mandiri, dan peran sebagai peer tutor.



Gambar 4. (j) Distribusi Skor Total per Profil, (k) Perbandingan Centroid per Dimensi & Profil

Model Matematika Final

Berdasarkan seluruh tahapan analisis, model matematika klasifikasi profil Mathematics SRL siswa SMP dapat dinyatakan secara formal sebagai berikut:

Fungsi Transformasi Data

$$z_j(x_i) = \frac{x_{ij} - \bar{\mu}_j}{\sigma_j} \text{ untuk } j \in \{GS, SM, SE, MK\}$$

Dengan $\bar{\mu}_{GS} = 3.36, \bar{\mu}_{SM} = 3.10, \bar{\mu}_{SE} = 3.37, \bar{\mu}_{MK} = 3.10$ dan $\sigma_{GS} = 0.35, \sigma_{SM} = 0.43, \sigma_{SE} = 0.52, \sigma_{MK} = 0.48$

Fungsi Penugasan Cluster

Penentuan cluster optimal: $C^*(x_i) = \arg \min_{k \in \{1,2,3\}} d(z_i, \mu_k^*)$

Fungsi jarak eucliden:

$$d(z_i, \mu_k^*) = \sqrt{(Z_{GS,i} - \mu_{k,GS}^*)^2 + (Z_{SM,i} - \mu_{k,SM}^*)^2 + (Z_{SE,i} - \mu_{k,SE}^*)^2 + (Z_{MK,i} - \mu_{k,MK}^*)^2}$$

Vektor Centroid Optimal (Ruang Z-Score)

$$\mu_1^* = \begin{bmatrix} -1.362 \\ -1.031 \\ -1.159 \\ -0.989 \end{bmatrix} \text{ (profil rendah), } \mu_2^* = \begin{bmatrix} -0.106 \\ -0.032 \\ -0.464 \\ -0.106 \end{bmatrix} \text{ (profil sedang), } \mu_3^* = \begin{bmatrix} -1.131 \\ 0.804 \\ 0.967 \\ 0.818 \end{bmatrix} \text{ (profil tinggi)}$$

tinggi)

Kriteria Klasifikasi Profil (Skala Asli)

Profil Rendah: $\bar{x}_i < 2.962 \leftrightarrow C^*(x_i) = 1$

Profil Sedang: $2.962 \leq \bar{x}_i < 3.400 \leftrightarrow C^*(x_i) = 2$

Profil Tinggi: $\bar{x}_i \geq 3.400 \leftrightarrow C^*(x_i) = 3$

Kualitas Model

Tabel 7. Ringkasan Kualitas Model K-Means (K=3)

Metrik Kualitas	Nilai	Interpretasi
WCSS Final (J*)	120.915	Fungsi objektif minimum tercapai
Silhouette Index	0.286	Fair clustering (SI > 0.25)
Signifikansi ANOVA	p < 0.001 (semua dim.)	Profil berbeda sangat signifikan
Variansi PC1 (PCA)	62.54%	Satu faktor SRL dominan
Cronbach's Alpha	0.823	Instrumen reliabel
n_init (stabilitas)	100	Solusi global, bukan lokal

Pembahasan

Temuan penelitian ini mengidentifikasi tiga profil Mathematics SRL siswa SMP yang terdistribusi sebagai berikut: Profil Tinggi (32.4%, n=22), Profil Sedang (45.6%, n=31), dan Profil Rendah (22.1%, n=15). Distribusi ini konsisten dengan pola yang ditemukan oleh Cleary et al. (Cleary et al., 2021) dan Landa et al. (Landa et al., 2024) yang juga mengidentifikasi tiga profil dengan distribusi mayoritas pada profil sedang.

Hasil analisis PCA yang menunjukkan PC1 menjelaskan 62.54% variansi ($\lambda = 2.502 \gg 1$) membuktikan adanya konstruk SRL umum (*general SRL factor*) yang kuat di antara keempat dimensi. Hal ini mendukung teori Zimmerman (Zimmerman, 2000) yang memandang SRL sebagai konstruk terpadu. Secara matematis, hal ini berarti keempat dimensi berkorelasi tinggi dan dapat diprediksi satu sama lain, yaitu siswa yang tinggi pada satu dimensi cenderung tinggi pada dimensi lainnya.

Temuan kritis lainnya adalah bahwa dimensi *Self-Efficacy* menghasilkan nilai F-ANOVA tertinggi ($F = 70.349$, $p < 0.001$), menunjukkan bahwa keyakinan diri dalam menghadapi soal matematika merupakan faktor paling diskriminan antar profil. Ini sejalan dengan teori Bandura (Bandura, 1991) tentang pentingnya *self-efficacy* sebagai prediktor utama perilaku regulasi diri. Implikasinya, intervensi yang paling efektif untuk meningkatkan SRL matematika siswa adalah dengan memperkuat *self-efficacy* terlebih dahulu, misalnya melalui pemberian *mastery experience* dan verbal persuasif.

Model matematika yang dihasilkan $C * (x_i) = \arg \min_{k \in \{1,2,3\}} d(z_i, \mu_k^*)$ dapat digunakan sebagai alat diagnostik otomatis. Guru dapat mengumpulkan data kuesioner, menghitung skor per dimensi, melakukan standarisasi, dan menghitung jarak Euclidean ke masing-masing *centroid* untuk mengklasifikasikan setiap siswa ke dalam profil yang sesuai. Proses ini dapat dioperasionalkan dalam spreadsheet sederhana atau aplikasi berbasis web.

PENUTUP

Penelitian ini berhasil membangun model matematis untuk klasifikasi profil *Mathematics Self-Regulated Learning* (SRL) siswa SMP menggunakan metode K-Means Clustering dalam kerangka Data Mining dan Machine Learning. Hasil analisis menunjukkan bahwa jumlah kluster optimal adalah tiga ($K = 3$) yang ditentukan melalui pendekatan Elbow Method dan Silhouette Index dengan nilai SI sebesar 0,286 ($> 0,25$) serta nilai WCSS minimum sebesar ($J^* = 120.915$). Berdasarkan hasil klusterisasi tersebut, siswa terkelompok ke dalam tiga profil utama, yaitu profil tinggi (32,4%), profil sedang (45,6%), dan profil rendah (22,1%), dengan perbedaan yang sangat signifikan pada seluruh dimensi SRL berdasarkan uji Analysis of Variance ($p < 0,001$). Model matematis akhir yang diperoleh, yaitu $c(x_i) = \arg \min_k \|x_i - \mu_k\|^2$, dengan *centroid* yang telah ditentukan, dapat digunakan sebagai alat diagnostik untuk mengidentifikasi profil SRL siswa baru secara langsung. Lebih lanjut, hasil analisis menunjukkan bahwa dimensi *self-efficacy* merupakan faktor paling diskriminan dengan nilai $F = 70,349$, sehingga intervensi pendidikan yang berfokus pada penguatan keyakinan diri siswa dipandang paling efektif dalam meningkatkan kemampuan *Mathematics Self-Regulated Learning*. Selain itu, analisis menggunakan *Principal Component Analysis* mengungkap adanya satu faktor umum SRL dengan nilai eigen ($\lambda = 2.502$) yang mampu menjelaskan 62,54% variansi data, sehingga mengonfirmasi koherensi konstruk instrumen yang digunakan dalam penelitian ini.

UCAPAN TERIMA KASIH

Ucapan terimakasih disampaikan kepada semua pihak yang mendukung terlaksananya penelitian ini terutama Rektor Universitas 17 Agustus 1945 Cirebon dan Para Guru Matematika SMPN 1 Cirebon.

REFERENSI

- Abdi, H., & Williams, L. J. (2010). Principal component analysis. *WIREs Computational Statistics*, 2(4), 433–459. <https://doi.org/https://doi.org/10.1002/wics.101>
- Arbelaitz, O., Gurrutxaga, I., Muguerza, J., Pérez, J. M., & Perona, I. (2013). An extensive comparative study of cluster validity indices. *Pattern Recognition*, 46(1), 243–256. <https://doi.org/10.1016/j.patcog.2012.07.021>
- Bandura, A. (1991). Social cognitive theory of self-regulation. *Organizational Behavior and Human Decision Processes*, 50(2), 248–287. [https://doi.org/https://doi.org/10.1016/0749-5978\(91\)90022-L](https://doi.org/https://doi.org/10.1016/0749-5978(91)90022-L)
- Bednorz, D., & Bruhn, S. (2023). Influence of primary students' self-regulated learning profiles on their rating of a technology-enhanced learning environment for mathematics. *Frontiers in Psychology*, 14. <https://doi.org/10.3389/fpsyg.2023.1074371>
- Callan, G. L., & Cleary, T. J. (2019). Examining cyclical phase relations and predictive influences of self-regulated learning processes on mathematics task performance. *Metacognition and Learning*, 14(1), 43–63. <https://doi.org/10.1007/s11409-019-09191-x>
- Cleary, T. J., Slempe, J., & Pawlo, E. R. (2021). Linking student self-regulated learning profiles to achievement and engagement in mathematics. *Psychology in the Schools*, 58(3), 443–457. <https://doi.org/https://doi.org/10.1002/pits.22456>
- Du, Y., & Liu, H. (2020). Analysis of the Influence of Psychological Contract on Employee Safety Behaviors against COVID-19. *International Journal of Environmental Research and Public Health*, 17(18). <https://doi.org/10.3390/ijerph17186747>

- Feddermann, M., Möller, J., & Baumert, J. (2021). Effects of CLIL on second language learning: Disentangling selection, preparation, and CLIL-effects. *Learning and Instruction*, 74, 101459. <https://doi.org/https://doi.org/10.1016/j.learninstruc.2021.101459>
- Granello, F., Cuder, A., Doz, E., Pellizzoni, S., & Passolunghi, M. C. (2025). "I can do math!": A self-regulated learning intervention to enhance math-related motivational factors and performance in middle school. *British Journal of Educational Psychology*. <https://doi.org/10.1111/bjep.70034>
- Guo, L., Cao, J., Cheng, P., Shi, D., Cao, B., Yang, G., Liang, S., Su, N., Yu, M., Zhang, C., Liang, R., Wang, Y., Bai, C., Chen, C., & Ren, Z. (2020). Moderate-to-Severe Depression Adversely Affects Lung Function in Chinese College Students. *Frontiers in Psychology*, Volume 11-2020. <https://doi.org/10.3389/fpsyg.2020.00652>
- Howard, Matt C, & Hoffman, Michael E. (2018). Variable-Centered, Person-Centered, and Person-Specific Approaches: Where Theory Meets the Method. *Organizational Research Methods*, 21(4), 846–876. <https://doi.org/10.1177/1094428117744021>
- Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. In *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* (Vol. 374, Number 2065). Royal Society of London. <https://doi.org/10.1098/rsta.2015.0202>
- Kaplan, C., & Bulbul, A. (2021). Goal driven network pruning for object recognition. *Pattern Recognition*, 110, 107468. <https://doi.org/https://doi.org/10.1016/j.patcog.2020.107468>
- Khalil, M., & Ebner, M. (2017). Clustering patterns of engagement in Massive Open Online Courses (MOOCs): the use of learning analytics to reveal student categories. *Journal of Computing in Higher Education*, 29(1), 114–132. <https://doi.org/10.1007/s12528-016-9126-9>
- Landa, J., Berciano, A., & Marbán, J. M. (2024). Self-Regulation Profiles of Pre-Service Mathematics Teachers for Primary Education in Mathematical Problem-Solving Contexts. *Education Sciences*, 14(9). <https://doi.org/10.3390/educsci14091018>
- OECD. (2023). *PISA 2022 Results (Volume I): The State of Learning and Equity in Education. , Paris: Volume 1*. PISA, OECD Publishing.
- Pintrich, P. R., Smith, D. A. F., Garcia, T., & McKeachie, W. J. (1991). *A Manual for the Use of the Motivated Strategies for Learning Questionnaire (MSLQ)*.
- Qi, H., Cruz, G., Botnar, R., & Prieto, C. (2021). Synergistic multi-contrast cardiac magnetic resonance image reconstruction. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(2200), 20200197. <https://doi.org/10.1098/rsta.2020.0197>
- Schunk, D. H., & Greene, J. A. (2017). *Handbook of Self-Regulation of Learning and Performance* ((2nd ed.)).
- Sholiha, T. A., Kurniati, N., Tyaningsih, R. Y., & Prayitno, S. (2022). Pengaruh Self-Regulated Learning (SRL) terhadap Hasil Belajar Matematika Siswa Kelas XI SMAN 1 Masbagik. *Jurnal Ilmiah Profesi Pendidikan*, 7(3), 1355–1362. <https://doi.org/10.29303/jipp.v7i3.745>
- Sinaga, K. P., & Yang, M. S. (2020). Unsupervised K-means clustering algorithm. *IEEE Access*, 8, 80716–80727. <https://doi.org/10.1109/ACCESS.2020.2988796>
- Stoner, O., & Economou, T. (2020). An advanced hidden Markov model for hourly rainfall time series. *Computational Statistics & Data Analysis*, 152, 107045. <https://doi.org/https://doi.org/10.1016/j.csda.2020.107045>
- Trouche, L., Rocha, K., Gueudet, G., & Pepin, B. (2020). Transition to digital resources as a critical process in teachers' trajectories: the case of Anna's documentation work. *ZDM*, 52(7), 1243–1257. <https://doi.org/10.1007/s11858-020-01164-8>

- Wild, S., & Neef, C. (2023). Analyzing the associations between motivation and academic performance via the mediator variables of specific mathematic cognitive learning strategies in different subject domains of higher education. *International Journal of STEM Education*, 10(1). <https://doi.org/10.1186/s40594-023-00423-w>
- Zimmerman, B. J. (2000). Chapter 2 - Attaining Self-Regulation: A Social Cognitive Perspective. In M. Boekaerts, P. R. Pintrich, & M. Zeidner (Eds.), *Handbook of Self-Regulation* (pp. 13–39). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-012109890-2/50031-7>