

Clustering Hasil Belajar Menggunakan Algoritma K-Means Dengan Optimize Parameter Dalam Menjamin Mutu Pendidikan Di Era Pandemi Covid-19

Ahmad Rifai, Fatihanursari Dikananda*, Christina Juliane

Program Studi Magister Sistem Informasi, STMIK LIKMI, Bandung, Indonesia

Email: ¹a.rifaai1408@gmail.com, ^{2,*}fatiha.dikananda@gmail.com, ³christina.juliane@likmi.ac.id

Email Penulis Korespondensi: fatiha.dikananda@gmail.com

Submitted:22/08/2022; Accepted:07/09/2022; Published: 30/09/2022

Abstrak—Pandemi Covid-19 sangat mempengaruhi lingkungan belajar, dengan alasan untuk menghentikan penyebaran infeksi Covid-19. Kegiatan Belajar Mengajar (KBM) yang selama ini umumnya diselesaikan di kampus secara tatap muka, kini harus dipindahkan ke Pembelajaran Jarak Jauh (PJJ). Namun, salah satu kekurangan pelaksanaan Pembelajaran Jarak Jauh (PJJ) adalah membuat mahasiswa kurang aktif sehingga KBM terasa melelahkan. Tujuan penelitian ini mengelompokkan hasil belajar mahasiswa di masa Pandemi Covid-19. Metode yang dipergunakan adalah Knowledge Discovery Database (KDD) menggunakan Algoritma K-Means. Jumlah cluster yang dipilih adalah jumlah cluster dengan nilai Davies Bouldin Index (DBI) terkecil. Hasil dari penelitian ini diperoleh 3 cluster dengan nilai DBI sebesar 1.379 dan Centroid Distance 0.342. Cluster_1 mewakili kelompok data yang memiliki indeks mutu tertinggi pertama, cluster_2 memiliki indeks mutu tertinggi kedua, dan cluster terakhir yakni cluster_0 adalah cluster yang mewakili data dengan indeks mutu terendah dari semua cluster. Dengan diketahui cluster hasil pembelajaran PJJ maka akan memudahkan perguruan tinggi dalam mengambil langkah – langkah improvement untuk meningkatkan mutu pembelajaran sesuai dengan karakteristik masing masing cluster yang ada.

Kata Kunci: Optimize parameter; Clustering; K-Means; DBI; Indeks Mutu

Abstract—The COVID-19 pandemic has greatly affected the learning environment, with the excuse of stopping the spread of COVID-19 infection. Teaching and learning activities that have generally been completed on campus face-to-face now have to be transferred to distance learning. However, one of the drawbacks of implementing distance learning is that it makes students less active, so that KBM feels tiring. The purpose of this study is to classify student learning outcomes during the COVID-19 Pandemic. The method used is the Knowledge Discovery Database (KDD) using the K-Means Algorithm. The number of clusters selected is the number of clusters with the smallest Davies Bouldin Index (DBI). The results of this study obtained 3 clusters with a DBI value of 1.379 and a centroid distance of 0.342. Cluster_1 is the data group with the highest quality index, Cluster_2 is the data group with the second highest quality index, and Cluster_0 is the data group with the lowest quality index of all clusters. By knowing the clusters of PJJ learning outcomes, it will make it easier for universities to take improvement steps to improve the quality of learning in accordance with the characteristics of each existing cluster.

Keywords: Optimize Parameter; Clustering; K-Means; DBI; Quality Index

1. PENDAHULUAN

Pendidikan sangat berperan penting dalam mengantarkan individu yang dewasa dan definitif baik yang benar-benar maupun secara intelektual terhubung dengan kepercayaan diri, pengabdian, informasi, imajinasi, otonomi, keterampilan, dan kewajiban. Selanjutnya, cenderung dianggap bahwa lembaga pendidik adalah kerangka penguasaan dalam hal informasi dan kemampuan yang diberikan untuk mengubah cara pandang atau perilaku manusia dengan tujuan akhir untuk dikembangkan melalui administrasi dan persiapan. Tugasnya sangat penting karena dengan Lembaga pendidikan yang berkualitas akan mempengaruhi penciptaan nilai dan Sumber Daya Manusia (SDM) yang sangat agresif [1].

Pandemi Covid-19 sangat mempengaruhi lingkungan belajar, dengan alasan untuk menghentikan penyebaran infeksi Covid-19, semua mahasiswa serta pendidik harus melakukan latihan belajar mengajar (KBM) dari rumah. Pendidik sebagai penentu kemajuan instruktif diharapkan lebih imajinatif dan kreatif dalam memilih teknik pembelajaran yang tepat sehingga hasil belajar mahasiswa dapat naik ke tingkat selanjutnya [2][3].

Kegiatan Belajar Mengajar (KBM) yang selama ini umumnya diselesaikan di kampus secara tatap muka, kini harus dipindahkan ke Pembelajaran Jarak Jauh (PJJ). Kerangka pembelajaran jarak jauh ini tidak mengharapkan mahasiswa datang ke kampus untuk menyelesaikan Kegiatan Belajar Mengajar (KBM). Namun, salah satu kekurangan pelaksanaan Pembelajaran Jarak Jauh (PJJ) adalah membuat mahasiswa kurang aktif dalam mengkomunikasikan keinginannya sehingga Kegiatan Belajar Mengajar (KBM) terasa melelahkan. Berkurangnya pertimbangan dan keaktifan mahasiswa dalam Kegiatan Belajar Mengajar (KBM) berpengaruh dengan signifikan terhadap hasil belajar mahasiswa. Oleh karena itu, dengan keadaan dan kondisi yang terbatas ini, dibutuhkan imajinasi dan kemampuan pendidik dalam membuat suatu penemuan yang dapat menonjolkan dan menggugah inspirasi mahasiswa untuk berpartisipasi dalam Kegiatan Belajar Mengajar (KBM) [1][4].

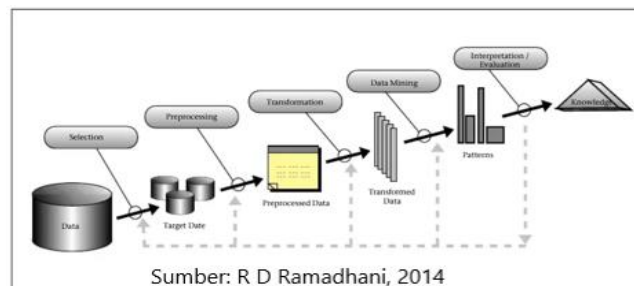
Penelitian ini bertujuan untuk mengelompokkan hasil belajar mahasiswa di masa Pandemi Covid-19, berdasarkan penelitian terdahulu yang telah dilakukan tentang clustering dengan Algoritma K-Means [5][13][16][17] tidak secara spesifik membahas penentuan jumlah kelompok berdasarkan nilai DBI yang maksimal, sehingga memerlukan peningkatan kinerja Algoritma *K-Means* melalui *Optimize parameter*, sehingga penelitian ini dilakukan menggunakan Algoritma *K-Means*. Dalam penentuan klasternya dapat dibuat sebanyak dua, tiga, empat dan

seterusnya, dimana setiap kluster mempunyai karakteristik yang sama [3]. Jumlah *cluster* terbaik dapat diuji menggunakan *Davies Bouldin Index* (DBI). Jumlah *cluster* yang dipilih adalah jumlah *cluster* dengan nilai DBI terkecil agar mempermudah perguruan tinggi untuk meningkatkan mutu pembelajaran sesuai dengan karakteristik masing-masing cluster.

2. METODOLOGI PENELITIAN

2.1 Data Mining

Data Mining digunakan untuk menemukan hubungan yang jelas dan menarik kesimpulan yang sebelumnya tidak diketahui dengan cara yang saat ini dapat dipahami dan berguna bagi pemilik data. Data mining yang disederhanakan sering disebut sebagai proses penyaringan atau "menambang" pengetahuan dari sejumlah besar data. Berdasarkan fungsinya data mining dikelompokkan ke dalam 6 (enam) kelompok menjadi *classification*, *clustering*, *regression*, *anomaly detection*, *association rule learning* dan *summarization*[6]. Istilah lain untuk data mining adalah *Knowledge Discovery Database* (KDD) [7][8], yaitu:



Gambar 1. Istilah Knowledge Discovery Database (KDD)

a. Data Selection

Membuat pengumpulan informasi yang objektif, memilih indeks informasi, atau fokus pada subset faktor atau pengujian informasi, di mana pengungkapan ini akan dilakukan oleh sistem penambangan. Hasil pilihan disimpan dalam dokumen yang berbeda dari kumpulan data fungsional [9].

b. Pre-Processing

Pre-Processing dan pembersihan informasi adalah kegiatan penting yang dilakukan seperti mengikuti keributan. Sistem pembersihan mencakup menghilangkan informasi salinan, memeriksa informasi yang bertentangan, dan memperbaiki kesalahan informasi, seperti kesalahan pencetakan. Informasi dapat ditingkatkan dengan informasi atau data luar yang berlaku.[9].

c. Transformation

Proses rekonsiliasi atas informasi yang telah dipilih, sehingga informasi tersebut sesuai untuk proses penambangan informasi. Adalah siklus yang sangat bergantung pada jenis atau contoh data yang dicari dalam kumpulan data [9].

d. Interpretation/ Evaluation

Menerapkan terjemahan dari beberapa contoh yang dibuat dari data mining. Pola data selanjutnya ditampilkan sebagai benda. Tahap ini menganalisis apakah contoh atau data yang ditemukan bertentangan dengan kenyataan saat ini atau spekulasi yang sudah ada [9].

2.2 Clustering

Teknik data mining untuk menganalisis data untuk memecahkan permasalahan dalam pengelompokan menggunakan metode *clustering*. *Clustering* akan melakukan proses segmentasi objek fisik ataupun non-fisik menjadi kelompok-kelompok data yang memiliki kesamaan. Pada teknik clustering targetnya adalah untuk kasus pendistribusian (objek, orang, peristiwa dan lainnya) ke dalam suatu kelompok, hingga derajat tingkat keterhubungan antar anggota *cluster* yang sama adalah kuat dan lemah antara anggota *cluster* yang berbeda [10][11][12][13].

2.3 K-Means Clustering

Metode *K-Means* telah diimplementasikan oleh Purnamaningsih et al., 2016 terhadap kajian yang berjudul Pemanfaatan Metode *K-Means* Clustering dalam Penentuan Penjurusan Siswa SMA, dimana hasilnya menunjukkan merupakan salah satu algoritma data *clustering* non-hirarki yang mengelompokkan data dalam bentuk satu atau lebih *cluster*/segmentasi data. Data-data akan dipartisi dengan algoritma *K-Means* kedalam cluster atau segmen sehingga data dengan karakteristik yang sama akan terkumpul dalam satu *Cluster* [14].

Dari beberapa kajian yang telah dilakukan [8][11][15] maka metode *K-Means clustering* terdiri dari langkah-langkah sebagai berikut:

a. Ambil jumlah *k-cluster*.

b. Inisiasi sebuah nilai random untuk pusat *cluster* awal (*centroid*) sejumlah nilai *k-cluster* yang diambil.



- c. Menghitung jarak untuk setiap data input terhadap masing-masing centroid berdasarkan rumus jarak (*Eucledian Distance*) hingga mencapai jarak terdekat maksimal dari setiap data dengan centroid. Berikut persamaan *Eucledian Distance*:

$$d(x_i, \mu_i) = \sqrt{((x_i - \mu_i))^2} \tag{1}$$

- d. Mengklasifikasi data menurut dekatnya jarak dengan *centroid*.
 e. Memperbarui nilai *centroid* berdasarkan rata-rata *cluster* yang bersangkutan dengan memakai rumus:

$$C_k = 1/n_k \sum d_i \tag{2}$$

Dimana:

n_k = jumlah data dalam *Cluster*

d_i = jumlah dari nilai jarak yang masuk dalam masin masing *Cluster*.

- f. Langkah 2 hingga 5 diulang hingga anggota tiap cluster tidak ada yang berubah.
 g. Jika langkah 6 telah tercapai, maka nilai rata-rata pusat cluster (μ_j) pada percobaan terakhir akan digunakan sebagai parameter untuk menentukan klasifikasi data.

Tabel 1. Parameter K-Mean

Parameter	Value
Measure type	NumericalMeasures
Nominal measure	EuclidianDistance
Max Optimization step	100
K	3
Max runs	10

2.4 Davies Bouldin Index

Davies Bouldin Index (DBI) merupakan ukuran untuk mengevaluasi kinerja *clustering*. Ide dasarnya adalah untuk mengevaluasi pemisahan antara cluster ke-i dan ke-j, yang harus sebesar mungkin antara *cluster* dan sekecil mungkin dalam *cluster*. DBI memiliki korelasi positif untuk "*within-class*" kasus dan korelasi negatif untuk kasus "*between-class*" [6]. Formula dari DBI adalah sebagai berikut :

$$B = \frac{1}{n_c} \sum_{i=1}^{n_c} R_i, \text{ where } R_i = \max_{j=1..n_c, i \neq j} R_{ij} = \frac{S_i + S_j}{d_{ij}} d_{ij} = d(v_i, v_j), \frac{1}{\|C_1\|} \sum_{x \in C} d(x, v_i) \tag{3}$$

2.5 Optimize Paramaters

Operator *Optimize Parameters* (Grid) merupakan operator bersarang. Operator ini mengeksekusi subproses untuk semua kombinasi nilai parameter yang dipilih dan kemudian memberikan nilai parameter optimal melalui port set parameter. Vektor kinerja untuk nilai parameter yang optimal dikirimkan melalui port kinerja dan model terkait (jika ada) melalui port model. Hasil tambahan apa pun dari proses terbaik dikirimkan melalui port output. Parameter mana yang optimal didasarkan pada nilai kinerja yang dikirimkan ke port kinerja bagian dalam [6].

Tabel 2. Seting Optimize parameters

Parameter	Value
Clustering	K
Minimum	2
Maximum	10
Step	10
Scale	Linear

2.6 Dataset

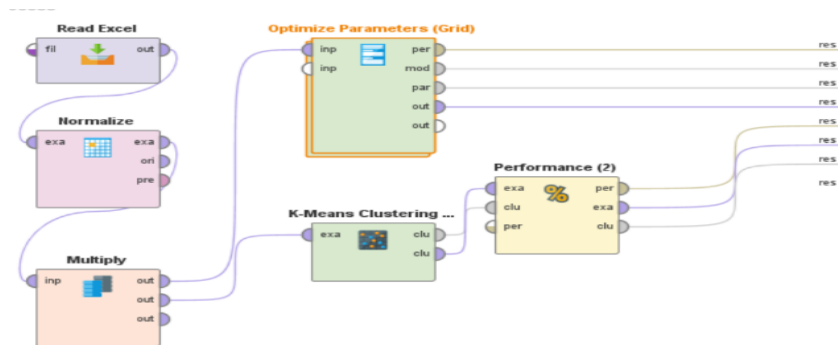
Dataset yang digunakan merupakan dataset hasil belajar mahasiswa program studi teknik informatika (S1) di STMIK IKMI Cirebon yang diperoleh melalui bagian akademik Tahun 2015 s/d tahun 2019 sebanyak 1084 dataset, dengan 16 atribut seperti terlihat pada table 3.

Tabel 3. Atribut dataset Hasil belajar mahasiswa

Variabel	Description	Variabel	Description
V1	IP Semester 1	V9	IP Semester 5
V2	Rata-Rata Kehadiran Semester 1	V10	Rata-Rata Kehadiran Semester 5
V3	IP Semester 2	V11	IP Semester 6
V4	Rata-Rata Kehadiran Semester 2	V12	Rata-Rata Kehadiran Semester 6
V5	IP Semester 3	V13	IP Semester 7
V6	Rata-Rata Kehadiran Semester 3	V14	Rata-Rata Kehadiran Semester 7
V7	IP Semester 4	V15	IP Semester 8
V8	Rata-Rata Kehadiran Semester 4	V16	Rata-Rata Kehadiran Semester 8

3. HASIL DAN PEMBAHASAN

Usecase model *clustering* hasil belajar menggunakan algoritma *K-Means* dengan *optimize parameters* seperti terlihat pada gambar 2, diawali dengan membaca datasheet menggunakan Operator *Read excel*. Selanjutnya dengan operator *multiple* untuk memilah proses *clustering* menggunakan *K-Mean+Optimize parameters* (OP) dan *K-Means*. Kemudian diterapkan Operator *Apply Model*. Untuk mengevaluasi *performance clustering* menggunakan Operator *cluster distance performance*. Berikut model proses *K-Means* menggunakan aplikasi Rapidminer :



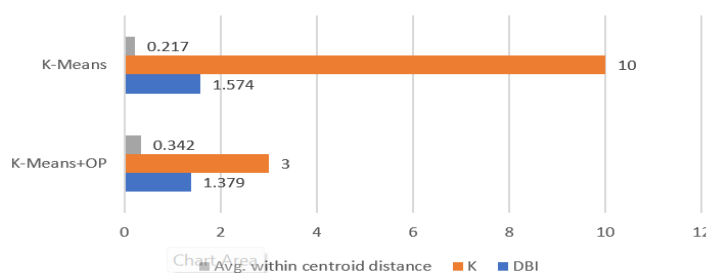
Gambar 2. Model Clustering dengan K-Means dengan Optimize parameters

Model proses *clustering K-Means* pada gambar 2 dilakukan untuk mencari nilai k atau jumlah *cluster* yang akan digunakan. Berdasarkan Hasil eksperimen dengan RapidMiner diperoleh hasil Parameter k = 3 dengan Nilai DBI 1.379 dan nilai *centroid distance* 0.342 dengan Algoritma *K-Mean+Optimize Parameters* (OP). Hasil lengkap eksperimen dapat dilihat pada table 4 serta dapat di visualisasikan dalam bentuk Grafik pada Gambar 3.

Tabel 4. Nilai DBI, K dan *Centroid distance* dengan *Optimize Parameters* (OP)

Nilai	DBI	K	Avg. within centroid distance
<i>K-Means+OP</i>	1.379	3	0.342
<i>K-Means</i>	1.574	10	0.217

Perbandingan Nilai DBI, K dan Avg within centroid distance



Gambar 3. Grafik Perbandingan nilai DBI, K dan *Centroid Distance* antara *K-Means+OP* dengan *K-Means*

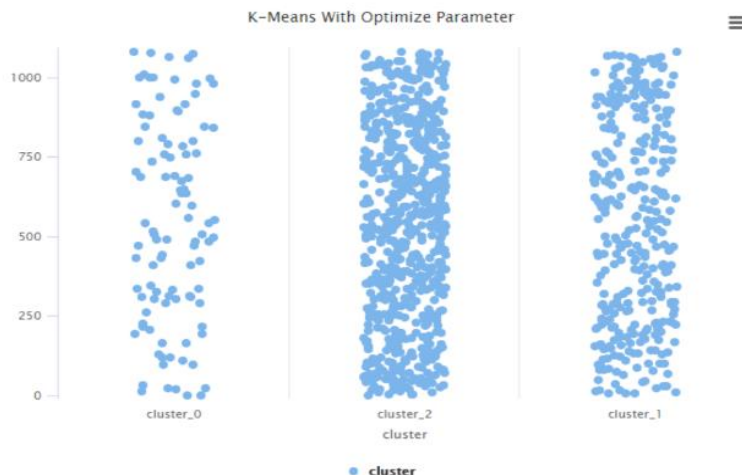
Hasil eksperimen diperoleh nilai-nilai *centroid distance* untuk setiap *cluster* dimulai dari *cluster_0* sampai dengan *cluster_2* untuk setiap atribut yang dapat dilihat pada Tabel 5.

Tabel 5. Centroid table hasil belajar terhadap 18 atribut


Attribute	Cluster_0	Cluster_1	Cluster_2
IP Semester 1	0.553	0.668	0.491
Rata-Rata Kehadiran Semester 1	0.266	0.377	0.380
IP Semester 2	0.532	0.674	0.470
Rata-Rata Kehadiran Semester 2	0.290	0.905	0.938
IP Semester 3	0.388	0.600	0.271
Rata-Rata Kehadiran Semester 3	0.358	0.374	0.372
IP Semester 4	0.344	0.556	0.256
Rata-Rata Kehadiran Semester 4	0.415	0.490	0.432
IP Semester 5	0.421	0.645	0.324
Rata-Rata Kehadiran Semester 5	0.415	0.490	0.432
IP Semester 6	0.385	0.587	0.309
Rata-Rata Kehadiran Semester 6	0.415	0.490	0.432
IP Semester 7	0.445	0.606	0.352
Rata-Rata Kehadiran Semester 7	0.290	0.905	0.938

IP Semester 8	0.593	0.692	0.525
Rata-Rata Kehadiran Semester 8	0.330	0.412	0.483

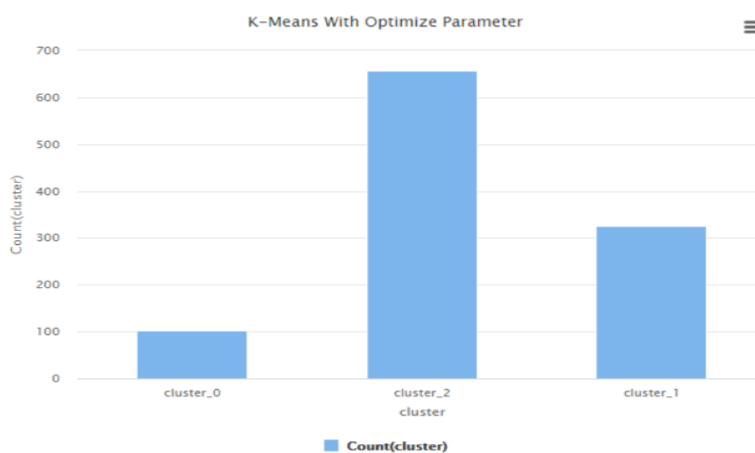
Hasil Eksperimen diperoleh menjadi 3 cluster yaitu *cluster_0* sebanyak 102 data, *cluster_1* sebanyak 326 data, *cluster_2* sebanyak 656 data, divisualisasikan dalam grafik scatter seperti pada gambar 3 dan grafik plot seperti pada gambar 4 serta grafik batang pada setiap cluster seperti pada gambar 5.



Gambar 4. Scatter/sebaran data hasil belajar terhadap rata-rata kehadiran dan ip selama 8 semester



Gambar 5. Grafik plot cluster hasil belajar berdasarkan 18 atribut



Gambar 6. Grafik Batang setiap cluster hasil belajar berdasarkan 16 atribut

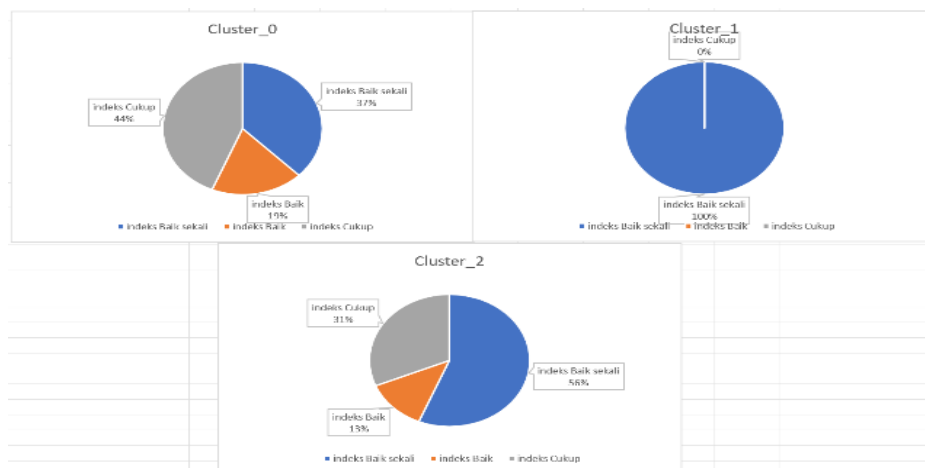
Setelah mendapatkan data *cluster* dan titik *centroid*, selanjutnya *centroid* dari *cluster* diberikan indeks mutu IP sebagai berikut 0.344-0.427= cukup, 0.428-0.51=baik, dan 0.52-0.510=baik sekali, dan indeks mutu rata-rata kehadiran dari 0.266-0.316=cukup, 0.317-0.365=baik, 0.366-0.415=baik sekali seperti pada tabel 5 untuk kemudian dilakukan analisa karakteristik dari setiap *cluster* yang telah didapat.

Dari tabel 6 sudah bisa dilihat pola dari setiap *cluster* data yang menunjukkan indeks mutu terhadap 16 atribut, dapat dikemukakan bahwa kelompok pertama adalah *cluster_1*, kelompok data dengan indeks mutu tertinggi pertama, memuat atribut hasil belajar dan rerata kehadiran dengan indeks mutu baik sekali sebanyak 16 atribut. Kelompok kedua adalah *cluster_2* dengan indeks mutu tertinggi kedua, memuat hasil belajar dan rerata kehadiran dengan indeks mutu baik sekali sebanyak 9 atribut, indeks mutu baik sebanyak 2 atribut, serta indeks mutu cukup sebanyak 5 atribut. Kelompok terakhir adalah *cluster_0*, kelompok dengan indeks mutu terendah dari semua *cluster* memuat hasil belajar dan rerata kehadiran dengan indeks mutu baik sekali sebanyak 6 atribut, indeks mutu baik 3 atribut, serta indeks mutu cukup sebanyak 7 atribut.

Tabel 6. Centroid table disertai indeks kepuasan terhadap 18 atribut

Atribut	Cluster_0	Indeks	Cluster_1	Indeks	Cluster_2	Indeks
IP Semester 1	0.553	Baik Sekali	0.668	Baik Sekali	0.491	Baik
Rata-Rata Kehadiran Semester 1	0.266	Cukup	0.377	Baik Sekali	0.380	Baik Sekali
IP Semester 2	0.532	Baik Sekali	0.674	Baik Sekali	0.470	Baik
Rata-Rata Kehadiran Semester 2	0.290	Cukup	0.905	Baik Sekali	0.938	Baik Sekali
IP Semester 3	0.388	Cukup	0.600	Baik Sekali	0.271	Cukup
Rata-Rata Kehadiran Semester 3	0.358	Baik	0.374	Baik Sekali	0.372	Baik Sekali
IP Semester 4	0.344	Cukup	0.556	Baik Sekali	0.256	Cukup
Rata-Rata Kehadiran Semester 4	0.415	Baik Sekali	0.490	Baik Sekali	0.432	Baik Sekali
IP Semester 5	0.421	Cukup	0.645	Baik Sekali	0.324	Cukup
Rata-Rata Kehadiran Semester 5	0.415	Baik Sekali	0.490	Baik Sekali	0.432	Baik Sekali
IP Semester 6	0.385	Cukup	0.587	Baik Sekali	0.309	Cukup
Rata-Rata Kehadiran Semester 6	0.415	Baik Sekali	0.490	Baik Sekali	0.432	Baik Sekali
IP Semester 7	0.445	Baik	0.606	Baik Sekali	0.352	Cukup
Rata-Rata Kehadiran Semester 7	0.290	Baik Sekali	0.905	Baik Sekali	0.938	Baik Sekali
IP Semester 8	0.593	Cukup	0.692	Baik Sekali	0.525	Baik Sekali
Rata-Rata Kehadiran Semester 8	0.330	Baik	0.412	Baik Sekali	0.483	Baik Sekali

Hasil eksperimen dapat dikemukakan bahwa *cluster_1* mewakili kelompok data yang memiliki indeks mutu tertinggi pertama dimana pada *cluster_1* menyatakan semua atribut 100% memiliki indeks mutu baik sekali. Pada *cluster_2* ini memiliki indeks mutu tertinggi kedua dengan menyatakan indeks mutu baik sekali sebanyak 56%, indeks mutu baik sebanyak 13%, serta indeks mutu cukup sebanyak 31% terhadap semua atribut. *Cluster* terakhir yakni *cluster_0* adalah *cluster* yang mewakili data dengan indeks mutu terendah dari semua *cluster* dengan menyatakan indeks mutu baik sekali sebanyak 37%, indeks mutu baik sebanyak 19%, serta indeks mutu cukup sebanyak 44% terhadap semua atribut seperti gambar 7.



Gambar 7. Grafik Batang setiap *cluster* hasil belajar berdasarkan 16 atribut

Berdasarkan penelitian terdahulu yang telah dilakukan tentang clustering dengan Algoritma K-Means [5][13][16][17] tidak secara spesifik membahas penentuan jumlah kelompok berdasarkan nilai DBI yang maksimal, sehingga memerlukan peningkatan kinerja Algoritma K-Means melalui *Optimize parameter*. Melalui *optimize parameters* dengan mensetup parameter *clustering.k* minimum 2 dan maksimum 10 dengan step 10 serta *scale linear*, akan membentuk kelompok minimum dari jumlah kelompok 2, sampai dengan jumlah kelompok 10 dengan menentukan nilai k berdasarkan nilai DBI yang terkecil. Nilai DBI terkecil diperoleh sebesar 1.379 dan *Centroid Distance* 0.342 diperoleh nilai k=3 yang berarti jumlah *cluster* yang terbentuk sebanyak 3. Nilai DBI ini menandakan bahwa dalam setiap kelompok tersebut setiap mahasiswa yang memiliki kemiripan yang tinggi tentang ip semester dan tingkat kehadiran, membentuk satu kelompok. Namun ada beberapa mahasiswa yang tingkat kemiripannya rendah tentang ip semester dan tingkat kehadirannya, masuk kedalam kelompok tersebut. Dengan demikian hasil penelitian ini merupakan sebuah kajian yang menarik dalam algoritma *clustering* dengan teknik *optimize parameter*.

4. KESIMPULAN

Pengelompokan mahasiswa berdasarkan atribut IP semester dan rata-rata kehadiran pada penelitian ini terdiri atas indeks mutu cukup, indeks mutu baik dan indeks mutu sangat baik. Pengelompokan indeks mutu cukup, indeks mutu baik dan indeks mutu sangat baik diperoleh setelah melalui proses perhitungan dengan menerapkan algoritma *K-Means Clustering* selesai. Berdasarkan hasil pengujian yang telah dilakukan, maka terbentuk segmentasi data mahasiswa yaitu *cluster_1* merupakan kelompok data yang memiliki indeks mutu tertinggi pertama dengan persentasi mahasiswa sebesar 30%. *Cluster_2* merupakan kelompok dengan indeks mutu tertinggi kedua dengan persentasi mahasiswa sebesar 61%. *Cluster* terakhir yakni *cluster_0* adalah *cluster* yang dengan indeks mutu terendah dari semua *cluster* yang terbentuk dengan persentasi mahasiswa sebesar 9%. Dari ke tiga *cluster* yang terbentuk tersebut dapat dikatakan bahwa kualitas mutu pembelajaran selama pandemi covid-19 di STMIK IKMI Cirebon dapat dikatakan berjalan dengan baik dan tidak mengalami penurunan terhadap nilai IP dan nilai rerata kehadiran pada setiap semesternya. Ini terlihat pada *cluster_1* dan *cluster_2* dimana sebesar 84% indeks mutu hasil belajarnya sudah baik/baik sekali dan 16% hasil belajarnya cukup. Namun masih ada kelompok ke tiga yaitu *cluster_0* dimana sebesar 56% indeks mutu hasil belajarnya baik/baik sekali dan 44% indeks mutu hasil belajarnya cukup. Pada *cluster_1* dan *cluster_2* tingkat rerata kehadiran sudah sangat tinggi, namun pada *cluster_0* tingkat kehadiran mahasiswa masih perlu ditingkatkan dalam rangka untuk meningkatkan ip semester. Strategi pengelompokan menggunakan Algoritma *K-Means* dapat memudahkan Perguruan Tinggi melakukan treatment terhadap kelompok-kelompok yang memerlukan perhatian khusus dalam melaksanakan proses pembelajaran dalam rangka untuk meningkatkan mutu Pendidikan di STMIK IKMI Cirebon. Rekomendasi untuk penelitian selanjutnya adalah perlunya dilakukan penelitian lanjutan tentang *clustering* menggunakan Algoritma *K-Means* untuk menentukan jumlah *cluster* yang maksimal dengan menerapkan operator yang lain dengan memperhatikan nilai *Davies Bouldin Index* (DBI) yang terkecil.

REFERENCES

- [1] E. Altania and Sungkono, "Jurnal EPISTEMA," *J. EPISTEMA*, vol. 2, no. 1, pp. 83–88, 2021.
- [2] Z. Yuhani, "UPAYA MENINGKATKAN HASIL BELAJAR SISWA PADA MASA PANDEMI COVID-19 DENGAN MICROSOFT KAIZALA UNTUK MATERI PELUANG," vol. 15, no. 2, pp. 1–23, 2019.
- [3] K. D. R. Sianipar, S. W. Siahaan, M. Siregar, F. I. R.H Zer, and D. Hartama, "Penerapan Algoritma K-Means Dalam Menentukan Tingkat Kepuasan Pembelajaran Online Pada Masa Pandemi Covid-19," *J. Teknol. Inf.*, vol. 4, no. 1, pp. 101–105, 2020, doi: 10.36294/jurti.v4i1.1258.
- [4] R. Chandra Saptono and P. Aziz, Abdul, "Pemanfaatan Metode K-Means Clustering dalam Penentuan Penjurusan Siswa SMA," *J. Teknol. Inf. ITSsmart*, vol. 3, no. 1, p. 27, 2018, doi: 10.20961/its.v3i1.644.
- [5] Z. Parveen, A. Alphones, and S. Naz, "Extending the Student's Performance via K-Means and Blended Learning," *Int. J. Eng. Appl. Comput. Sci.*, vol. 02, no. 04, pp. 133–136, 2017, doi: 10.24032/ijeacs/0204/03.
- [6] K. Ralf Hoffmann, Markus, *Data Mining Use Cases and Edited by*. 2017. [Online]. Available: <http://arxiv.org/abs/1706.03428>
- [7] M. Elly Kiswati, Sri, "Penerapan Metode K-Means Untuk Clustering Produk Online Shop Dalam Penentuan Stok Barang," *J. Bianglala Inform.*, vol. 3, no. 1, pp. 10–17, 2017.
- [8] R. Rima Dias, "Data Mining Menggunakan Algoritma K-Means Clustering Untuk Menentukan Strategi Promosi Universitas Dian Nuswantoro," *Ind. Mark. Manag.*, vol. 1, no. 1, pp. 1–9, 2018.
- [9] F. M. Basysyar, "Clustering Data Disabilitas menggunakan Algoritma K-Means di Kabupaten Cirebon," *JURSIMA (Jurnal Sist. Inf. dan ...)*, vol. 9, no. 3, 2021, [Online]. Available: <https://ejournal.stmikgici.ac.id/index.php/jursima/article/view/305>
- [10] D. Sudrajat, R. D. Dana, N. Rahaningsih, A. R. Dikananda, and D. A. Kurnia, "Clustering student's satisfaction in complex adaptive blended learning with the six value system using the K-means algorithm," *Universal Journal of Educational Research*, vol. 7, no. 9, pp. 1990–1995, 2019, doi: 10.13189/ujer.2019.070920.
- [11] N. R. Sofi Defiyanti, Mohamad Jajuli, "Implementasi Algoritma K-Means Dalam Pengklasteran Mahasiswa Pelamar Beasiswa," *Jitter 2017*, vol. I, no. 2, pp. 62–68, 2017.
- [12] A. Rizal, "Penerapan Data Mining dengan Menggunakan Metode Clustering K-Mean Untuk Mengukur Tingkat Ketepatan Kelulusan Mahasiswa Program Teknik Informatika S1 Fakultas Ilmu Komputer Universitas Dian Nuswantoro," *Dok. Karya Ilm.*, 2018, [Online]. Available: <http://dinus.ac.id/>
- [13] D. B. Valdez and R. A. G. Godmalin, "Clustering of Learners based on Readiness to Online Modality using K-Means Algorithm," *Int. J. Adv. Eng. Manag. Sci.*, vol. 7, no. 9, pp. 01–05, 2021, doi: 10.22161/ijaems.79.1.
- [14] D. Triyansyah and D. Fitriana, "Analisis Data Mining Menggunakan Algoritma K-Means Clustering Untuk Menentukan Strategi Marketing," *J. Telekomun. dan Komput.*, vol. 8, no. 3, p. 163, 2018, doi: 10.22441/incomtech.v8i3.4174.
- [15] O. J. Oladipupo, O. O. Obagbuwa, I. C. Oyelade, "Application of K-Means Clustering algorithm for prediction of Students Academic Performance," vol. 7, pp. 292–295, 2017.
- [16] I. Hedayetul Haque, Mahfuza, "An Approach of Improving Student's Academic Performance by using K-means clustering algorithm and Decision tree," *Int. J. Adv. Comput. Sci. Appl.*, vol. 3, no. 8, pp. 146–149, 2017, doi: 10.14569/ijacsa.2012.030824.
- [17] T. Mehta, C. W. Leathers, and M. R. Foster, David M. McCall, "Psyllium Husk II: Effect On The Metabolism Of Apolipoprotein B in African Green Monkeys," *Am. J. Clin. Nutr.*, vol. 56, no. 2, pp. 385–393, 2017, doi: 10.1093/ajcn/56.2.385.