



**TUGAS AKHIR - SA234801**

**ANALISIS *CLUSTERING* PADA BPR DAN BPRS MENGGUNAKAN ALGORITMA *K-MEANS*, *FUZZY C-MEANS*, DAN *SELF ORGANIZING MAP***

**AMARA SABHINAYA KAWIYANTO**

**NRP 5006 21 1 098**

Dosen Pembimbing

**Prilyandari Dina Saputri, S.Si., M.Stat.**

**NIP 19950404 202406 2 001**

**Program Studi Sarjana Sains Aktuaria**

Departemen Aktuaria

Fakultas Sains Dan Analitika Data

Institut Teknologi Sepuluh Nopember

Surabaya

2025





**TUGAS AKHIR - SA234801**

**ANALISIS *CLUSTERING* PADA BPR DAN BPRS MENGGUNAKAN  
ALGORITMA *K-MEANS*, *FUZZY C-MEANS*, DAN *SELF ORGANIZING MAP***

**AMARA SABHINAYA KAWIYANTO**

**NRP 5006 21 1 098**

Dosen Pembimbing

**Priyandari Dina Saputri, S.Si., M.Stat.**

**NIP 19950404 202406 2 001**

**Program Studi Sarjana Sains Aktuaria**

Departemen Aktuaria

Fakultas Sains Dan Analitika Data

Institut Teknologi Sepuluh Nopember

Surabaya

2025





**FINAL PROJECT - SA234801**

**CLUSTERING ANALYSIS IN RURAL BANKS AND SHARIA RURAL BANKS  
USING K-MEANS, FUZZY C-MEANS, AND SELF-ORGANIZING MAP  
ALGORITHMS**

**AMARA SABHINAYA KAWIYANTO**

**NRP 5006 21 1 098**

Advisor

**Priyandari Dina Saputri, S.Si., M.Stat.**

**NIP 19950404 202406 2 001**

**Undergraduate Study Program of Actuarial Science**

Departement of Actuarial Science

Faculty of Science and Data Analytics

Institut Teknologi Sepuluh Nopember

Surabaya

2025



## LEMBAR PENGESAHAN

### ANALISIS *CLUSTERING* PADA BPR DAN BPRS MENGGUNAKAN ALGORITMA *K-MEANS*, *FUZZY C-MEANS*, DAN *SELF ORGANIZING MAP*

#### TUGAS AKHIR

Diajukan untuk memenuhi salah satu syarat  
memperoleh gelar Sarjana Ilmu Aktuaria pada  
Program Studi Sarjana Sains Aktuaria  
Departemen Aktuaria  
Fakultas Sains dan Analitika Data  
Institut Teknologi Sepuluh Nopember

Oleh: **Amara Sabhinaya Kawiyo**  
NRP. 5006 21 1 098

Disetujui oleh Tim Penguji Tugas Akhir:

- |   |            |   |
|---|------------|---|
| 1. Prilyandari Dina Saputri, S.Si., M.Stat. | Pembimbing | (  ) |
| 2. Ulil Azmi, S.Si., M.Si., M.Sc.           | Penguji    | (  ) |
| 3. Dimaz Wisnu Adipradana, S.Si., M.Si.     | Penguji    | (  ) |

SURABAYA

Juli, 2025



## APPROVAL SHEET

### CLUSTERING ANALYSIS IN RURAL BANKS AND SHARIA RURAL BANKS USING K-MEANS, FUZZY C-MEANS, AND SELF- ORGANIZING MAP ALGORITHMS

#### FINAL PROJECT

Submitted to fulfill one of the requirements  
for obtaining a degree Bachelor of Actuarial Science at  
Undergraduate Study Program of Actuarial Science  
Departement of Actuarial Science  
Faculty of Science and Data Analytics  
Institut Teknologi Sepuluh Nopember

By: **Amara Sabhinaya Kawiyo**

NRP. 5006 21 1 098

Approved by Final Project Examiner Team:

- |   |          |   |
|---|----------|---|
| 1. Prilyandari Dina Saputri, S.Si., M.Stat. | Advisor  | (  ) |
| 2. Ulil Azmi, S.Si., M.Si., M.Sc.           | Examiner | (  ) |
| 3. Dimaz Wisnu Adipradana, S.Si., M.Si.     | Examiner | (  ) |

SURABAYA

July, 2025



## PERNYATAAN ORISINALITAS

Yang bertanda tangan di bawah ini:

Nama Mahasiswa/NRP : Amara Sabhinaya Kawayanto/5006211098  
Program Studi : Sains Aktuaria FSAD – ITS  
Dosen Pembimbing/NIP : Prilyandari Dina Saputri, S.Si., M.Stat./  
19950404 202406 2 001

dengan ini menyatakan bahwa Tugas Akhir dengan judul “Analisis *Clustering* Pada BPR dan BPRS menggunakan Algoritma *K-Means*, *Fuzzy C-Means*, dan *Self Organizing Map*” adalah hasil karya sendiri, bersifat orisinal, dan ditulis dengan mengikuti kaidah penulisan ilmiah.

Bilamana di kemudian hari ditemukan ketidaksesuaian dengan pernyataan ini, maka saya bersedia menerima sanksi sesuai dengan ketentuan yang berlaku di Institut Teknologi Sepuluh Nopember.

Surabaya, Juli 2025

Mengetahui,  
Dosen Pembimbing



Prilyandari Dina Saputri, S.Si., M.Stat.  
NIP. 19950404 202406 2 001

Mahasiswa



Amara Sabhinaya Kawayanto  
NRP. 5006211098



## STATEMENT OF ORIGINALITY

The undersigned below:

Nama of Student/NRP : Amara Sabhinaya Kawiyanto/5006211098  
Study Program : Actuarial Science FSAD – ITS  
Advisor/NIP : Prilyandari Dina Saputri, S.Si., M.Stat./  
19950404 202406 2 001

hereby declare that the Final Project with the title of “Clustering Analysis in Rural Banks and Sharia Rural Banks using K-Means, Fuzzy C-Means, and Self-Organizing Map Algorithms” is the result of my own work, is original, and is written by following the rules of scientific writing.

If in the future there is a discrepancy with this statement, then I am willing to accept sanctions in accordance with the provisions that apply at Institut Teknologi Sepuluh Nopember.

Surabaya, July 2025

Acknowledge,  
Advisor



Prilyandari Dina Saputri, S.Si., M.Stat.  
NIP. 19950404 202406 2 001

Student



Amara Sabhinaya Kawiyanto  
NRP. 5006211098



## ABSTRAK

### ANALISIS *CLUSTERING* PADA BPR DAN BPRS MENGGUNAKAN ALGORITMA *K-MEANS*, *FUZZY C-MEANS*, DAN *SELF ORGANIZING MAP*

Nama Mahasiswa : Amara Sabhinaya Kawiyo  
NRP : 5006211098  
Departemen : Aktuaria FSAD – ITS  
Dosen Pembimbing : Prilyandari Dina Saputri, S.Si., M.Stat.

#### Abstrak

Perbankan memiliki peranan penting dalam perekonomian suatu negara, termasuk Bank Perekonomian Rakyat (BPR) dan Bank Pembiayaan Rakyat Syariah (BPRS) yang melayani segmen kecil dan mikro. Namun, keduanya menghadapi beberapa tantangan seperti tingkat likuiditas yang rendah dan risiko kredit yang tinggi dibandingkan dengan bank umum konvensional maupun syariah. Oleh karena itu, penilaian tingkat kesehatan bank menjadi aspek yang krusial dalam memastikan keberlanjutan operasional perbankan. Penelitian ini bertujuan mengelompokkan BPR dan BPRS di wilayah Surabaya Raya berdasarkan tingkat kesehatannya menggunakan analisis *clustering*. Algoritma yang digunakan dalam analisis ini antara lain *k-means*, *fuzzy c-means*, serta *Self Organizing Map* (SOM). Validitas hasil *clustering* akan diukur menggunakan *Silhouette index* (Sil), *Davies-Bouldin index* (DB), dan *Calinski-Harabasz index* (CH) untuk menentukan metode pengelompokan terbaik. Hasil penelitian menunjukkan bahwa klusterisasi *fuzzy c-means* menghasilkan nilai validitas yakni *Silhouette index* sebesar 0,9788 untuk BPR dan 0,8168 untuk BPRS, *Davies-Bouldin index* sebesar 0,0784 untuk BPR dan 0,1270 untuk BPRS, serta *Calinski-Harabasz index* sebesar 598,2775 untuk BPR dan 41,1124 untuk BPRS. Nilai validitas tersebut merupakan nilai yang paling optimal jika dibandingkan dengan *k-means* dan *Self-Organizing Map*. Dengan demikian, diperoleh 3 kluster optimal yang terbentuk dengan algoritma *fuzzy c-means* yaitu kluster dengan tingkat kesehatan baik berisi 2 BPR, kluster dengan tingkat kesehatan cukup baik berisi 81 BPR, dan kluster dengan tingkat kesehatan kurang baik berisi 1 BPR. Sedangkan pada BPRS diperoleh 2 kluster optimal yang terbentuk yaitu kluster dengan tingkat kesehatan baik berisi 1 BPRS dan kluster dengan tingkat kesehatan kurang baik berisi 6 BPRS. Saran yang dapat diberikan berdasarkan hasil penelitian ini adalah bagi pemerintah khususnya OJK agar lebih aktif dan intensif mengawasi kinerja keuangan BPR dan BPRS yang dikategorikan ke dalam kluster tingkat kesehatan perbankan kurang baik.

**Kata kunci:** BPR, BPRS, *Clustering*, *Fuzzy C-means*, *K-means*, *Self-Organizing Map*



## ABSTRACT

### CLUSTERING ANALYSIS IN RURAL BANKS AND SHARIA RURAL BANKS USING K-MEANS, FUZZY C-MEANS, AND SELF-ORGANIZING MAP ALGORITHMS

**Student Name** : Amara Sabhinaya Kawiyanto  
**NRP** : 5006211098  
**Department** : Actuarial Science FSAD – ITS  
**Advisor** : Prilyandari Dina Saputri, S.Si., M.Stat.

#### Abstract

Bank plays a crucial role in a country's economy, including rural banks and sharia rural banks, which serve the small and micro segments. However, both face several challenges, such as low liquidity levels and high credit risk compared to commercial banks. Therefore, assessing the financial health of bank is a critical aspect in ensuring the sustainability of banking operations. This study aims to grouping BPR and BPRS in the Surabaya Raya area based on their financial health using clustering analysis. The algorithms used in this analysis including k-means, fuzzy c-means, and Self-Organizing Map (SOM). The validity of the clustering results is evaluated using the Silhouette Index (Sil), Davies-Bouldin Index (DB), and Calinski-Harabasz Index (CH) to determine the most effective clustering method. The findings indicate that the fuzzy c-means clustering algorithm results the most optimal validity scores, with Silhouette Index of 0,9788 for BPR and 0,8168 for BPRS, Davies-Bouldin Index of 0,0784 for BPR and 0,1270 for BPRS, and also Calinski-Harabasz Index of 598,2775 for BPR and 41,1124 for BPRS. These scores outperform other clustering results obtained using k-means or SOM algorithms. Based on the fuzzy c-means clustering results, three optimal clusters were identified for BPR: good financial health cluster containing 2 BPR, moderate financial health cluster comprising 81 BPR, and poor financial health cluster consisting of 1 BPR. For BPRS, two optimal clusters were identified: good financial health cluster containing 1 BPRS and poor financial health cluster consisting of 6 BPRS. Based on these findings, it is recommended that the government, particularly Otoritas Jasa Keuangan intensify its oversight of the financial performance of BPR and BPRS bankings categorized in the poor financial health cluster.

**Keywords:** Clustering, Fuzzy C-means, K-means, Rural banks, Self-Organizing Map, Sharia rural banks



## KATA PENGANTAR

Puji syukur kepada Allah SWT karena atas berkah dan rahmat-Nya penulis dapat menyelesaikan tugas akhir yang berjudul “Analisis *Clustering* pada BPR dan BPRS menggunakan Algoritma *K-Means*, *Fuzzy C-Means*, dan *Self Organizing Map*”. Penulisan tugas akhir ini dilakukan untuk memenuhi salah satu syarat memperoleh gelar Sarjana Ilmu Aktuaria dari Program Studi Sarjana Sains Aktuaria Institut Teknologi Sepuluh Nopember Surabaya. Penulisan ini tidak dapat terselesaikan tanpa bimbingan, bantuan, dan dukungan dari berbagai pihak. Oleh karenanya, pada kesempatan ini penulis mengucapkan terimakasih kepada:

1. Bapak R. Mohammad Atok, S.Si., M.Si., Ph.D selaku Kepala Departemen Aktuaria FSAD ITS.
2. Ibu Priyandari Dina Saputri, S.Si., M.Stat. selaku dosen pembimbing yang telah bersedia menyediakan waktu dalam memberikan bimbingan, arahan, saran, dan ilmu kepada penulis selama penyusunan tugas akhir ini.
3. Ibu Ulil Azmi, S.Si., M.Si., M.Sc. dan Bapak Dimaz Wisnu Adipradana, S.Si., M.Si. selaku dosen penguji yang telah memberikan saran dan arahan yang membangun dalam penyelesaian tugas akhir ini.
4. Seluruh dosen Departemen Aktuaria yang telah membagikan ilmu pengetahuan yang berguna untuk penyusunan tugas akhir ini.
5. Orang tua dan keluarga tercinta yang telah memotivasi, mendoakan, dan memberikan dukungan penuh sehingga penulis dapat menyelesaikan tugas akhir ini.
6. Teman-teman angkatan 2021 terutama teman-teman terdekat penulis Ita, Yosephine, Inda, Vita, dan Tika yang telah memberikan dukungan dan motivasi selama penyelesaian tugas akhir ini.
7. Serta semua pihak yang telah membantu penulis dalam melaksanakan penelitian ini yang tidak dapat penulis sebutkan satu persatu.

Penulis menyadari adanya ketidaksempurnaan dalam penyusunan tugas akhir ini, maka penulis mengharapkan kritik dan saran yang membangun. Akhir kata, semoga tugas akhir ini dapat bermanfaat dan memberikan wawasan bagi para pembaca.

Surabaya, Juli 2025

Penulis



## DAFTAR ISI

LEMBAR PENGESAHAN .....	iii
<i>APPROVAL SHEET</i> .....	v
PERNYATAAN ORISINALITAS .....	vii
<i>STATEMENT OF ORIGINALITY</i> .....	ix
ABSTRAK.....	xi
<i>ABSTRACT</i> .....	xiii
KATA PENGANTAR .....	xv
DAFTAR ISI .....	xvii
DAFTAR GAMBAR .....	xix
DAFTAR TABEL .....	xxi
DAFTAR LAMPIRAN .....	xxiii
DAFTAR SIMBOL .....	xxv
<b>BAB I PENDAHULUAN</b> .....	1
1.1. Latar Belakang .....	1
1.2. Rumusan Masalah.....	3
1.3. Tujuan .....	4
1.4. Manfaat .....	4
1.5. Batasan Penelitian.....	4
<b>BAB II TINJAUAN PUSTAKA</b> .....	5
2.1. Hasil Penelitian Terdahulu .....	5
2.2. Perbankan .....	6
2.2.1. Bank Umum .....	6
2.2.2. Bank Perekonomian Rakyat (BPR) .....	6
2.2.3. Prinsip Konvensional dan Syariah .....	7
2.3. Tingkat Kesehatan Bank.....	7
2.3.1. Profil Risiko ( <i>Risk Profile</i> ) .....	8
2.3.2. Tata Kelola ( <i>Good Corporate Governance</i> ) .....	9
2.3.3. Rentabilitas ( <i>Earnings</i> ) .....	9
2.3.4. Permodalan ( <i>Capital</i> ).....	10
2.4. <i>Preprocessing</i> Data.....	11
2.5. Analisis <i>Clustering</i> .....	11
2.6. Asumsi Multikolinearitas.....	12
2.7. <i>K-means Clustering</i> .....	13
2.8. <i>Fuzzy C-means Clustering</i> .....	15
2.9. <i>Self-Organizing Map (SOM) Clustering</i> .....	17

2.10. Kriteria Evaluasi <i>Cluster</i> .....	19
2.10.1. <i>Silhouette Index</i> (Sil) .....	19
2.10.2. <i>Davies-Bouldin Index</i> (DB) .....	20
2.10.3. <i>Calinski-Harabasz Index</i> (CH) .....	21
<b>BAB III METODOLOGI PENELITIAN</b> .....	23
3.1. Sumber Data dan Variabel Penelitian .....	23
3.2. Langkah Analisis .....	24
3.3. Diagram Alir Penelitian .....	26
<b>BAB IV HASIL DAN PEMBAHASAN</b> .....	31
4.1. Gambaran Umum Objek Penelitian .....	31
4.2. Analisis Deskriptif Variabel .....	32
4.3. Hasil Identifikasi Multikolinearitas .....	36
4.4. Standarisasi Data .....	37
4.5. Klasterisasi Menggunakan Algoritma <i>K-means</i> .....	39
4.5.1. BPR .....	39
4.5.2. BPRS .....	45
4.6. Klasterisasi Menggunakan Algoritma <i>Fuzzy C-means</i> .....	49
4.6.1. BPR .....	50
4.6.2. BPRS .....	56
4.7. Klasterisasi Menggunakan Algoritma <i>Self-Organizing Map</i> (SOM) .....	62
4.7.1. BPR .....	62
4.7.2. BPRS .....	69
4.8. Evaluasi Hasil Klasterisasi .....	74
4.9. Interpretasi Hasil Klaster Terbaik .....	75
4.9.1. BPR .....	75
4.9.2. BPRS .....	78
<b>BAB V PENUTUP</b> .....	81
5.1. Kesimpulan .....	81
5.2. Saran .....	82
<b>DAFTAR PUSTAKA</b> .....	83
<b>LAMPIRAN</b> .....	87
<b>BIODATA PENULIS</b> .....	105

## DAFTAR GAMBAR

<b>Gambar 2.1</b>	Ilustrasi Hasil Analisis <i>Clustering</i> .....	12
<b>Gambar 2.2</b>	Contoh Visualisasi <i>Clustering</i> dengan Algoritma <i>K-means</i> .....	13
<b>Gambar 2.3</b>	Contoh Visualisasi FCM <i>Clustering</i> .....	16
<b>Gambar 2.4</b>	Struktur Dasar Jaringan SOM .....	18
<b>Gambar 2.5</b>	Ilustrasi Perhitungan Indeks <i>Silhouette</i> pada Objek <i>i</i> pada Klaster A .....	19
<b>Gambar 2.6</b>	Ilustrasi Validitas <i>Cluster</i> dengan Indeks <i>Davies-Bouldin</i> .....	20
<b>Gambar 3.1</b>	Alur Penelitian .....	26
<b>Gambar 3.2</b>	Diagram Alir Algoritma <i>K-means</i> .....	27
<b>Gambar 3.3</b>	Diagram Alir Algoritma <i>Fuzzy C-means</i> .....	28
<b>Gambar 3.4</b>	Diagram Alir Algoritma SOM .....	29
<b>Gambar 4.1</b>	Histogram Rasio NPL BPR (a) dan BPRS (b) .....	33
<b>Gambar 4.2</b>	Histogram Rasio LDR BPR (a) dan BPRS (b) .....	34
<b>Gambar 4.3</b>	Histogram Rasio BOPO BPR (a) dan BPRS (b) .....	34
<b>Gambar 4.4</b>	Histogram Rasio ROA BPR (a) dan BPRS (b) .....	35
<b>Gambar 4.5</b>	Histogram Rasio NIM BPR (a) dan NI BPRS (b) .....	35
<b>Gambar 4.6</b>	Histogram Rasio KPMM BPR (a) dan BPRS (b) .....	36
<b>Gambar 4.7</b>	Plot <i>Mapping</i> (a) dan <i>Codes</i> (b) Hasil Klasterisasi BPR Terbaik .....	68
<b>Gambar 4.8</b>	Plot <i>Mapping</i> (a) dan <i>Codes</i> (b) Hasil Klasterisasi BPRS Terbaik .....	73
<b>Gambar 4.9</b>	<i>Boxplot</i> Ketiga Cluster pada 6 Variabel BPR .....	76
<b>Gambar 4.10</b>	<i>Boxplot</i> Kedua Cluster pada 4 Variabel BPRS .....	78



## DAFTAR TABEL

<b>Tabel 2.1</b>	Penelitian Terdahulu .....	5
<b>Tabel 3.1</b>	Variabel Indikator Tingkat Kesehatan BPR dan BPRS.....	23
<b>Tabel 3.2</b>	Rekap Jumlah BPR dan BPR di Surabaya Raya .....	23
<b>Tabel 3.3</b>	Struktur Data Penelitian.....	24
<b>Tabel 4.1</b>	Daftar BPR di Surabaya Raya .....	31
<b>Tabel 4.2</b>	Daftar BPRS di Surabaya Raya .....	32
<b>Tabel 4.3</b>	Statistika Deskriptif Data.....	32
<b>Tabel 4.4</b>	Nilai VIF Variabel BPR dan BPRS .....	37
<b>Tabel 4.5</b>	Nilai VIF Variabel BPRS yang Telah Memenuhi Asumsi.....	37
<b>Tabel 4.6</b>	Data 6 Variabel BPR.....	37
<b>Tabel 4.7</b>	Data 4 Variabel BPRS .....	38
<b>Tabel 4.8</b>	Data Standarisasi 6 Variabel BPR .....	38
<b>Tabel 4.9</b>	Data Standarisasi 4 Variabel BPRS .....	38
<b>Tabel 4.10</b>	Evaluasi Hasil Klasterisasi BPR dengan Algoritma <i>K-means</i> .....	43
<b>Tabel 4.11</b>	Pusat Kluster BPR Terbaik dengan <i>K-means</i> .....	43
<b>Tabel 4.12</b>	Data Jarak dari Hasil Klasterisasi BPR Terbaik dengan <i>K-means</i> .....	43
<b>Tabel 4.13</b>	Hasil Klasterisasi BPR Terbaik dengan <i>K-means</i> .....	44
<b>Tabel 4.14</b>	Evaluasi Hasil Klasterisasi BPRS dengan Algoritma <i>K-means</i> .....	48
<b>Tabel 4.15</b>	Pusat Kluster BPRS Terbaik dengan <i>K-means</i> .....	48
<b>Tabel 4.16</b>	Data Jarak dari Hasil Klasterisasi BPRS Terbaik dengan <i>K-means</i> .....	49
<b>Tabel 4.17</b>	Hasil Klasterisasi BPRS Terbaik dengan <i>K-means</i> .....	49
<b>Tabel 4.18</b>	Evaluasi Hasil Klasterisasi BPR dengan Algoritma <i>Fuzzy C-means</i> .....	54
<b>Tabel 4.19</b>	Pusat Kluster BPR Terbaik dengan <i>Fuzzy C-means</i> .....	55
<b>Tabel 4.20</b>	Derajat Keanggotaan Hasil Klasterisasi BPR Terbaik dengan <i>Fuzzy C-means</i> ....	55
<b>Tabel 4.21</b>	Hasil Klasterisasi BPR Terbaik dengan <i>Fuzzy C-means</i> .....	55
<b>Tabel 4.22</b>	Evaluasi Hasil Klasterisasi BPRS dengan Algoritma <i>Fuzzy C-means</i> .....	60
<b>Tabel 4.23</b>	Pusat Kluster BPRS Terbaik dengan <i>Fuzzy C-means</i> .....	61
<b>Tabel 4.24</b>	Derajat Keanggotaan Hasil Klasterisasi BPRS Terbaik dengan <i>Fuzzy C-means</i> ..	61
<b>Tabel 4.25</b>	Hasil Klasterisasi BPRS Terbaik dengan <i>Fuzzy C-means</i> .....	61
<b>Tabel 4.26</b>	Evaluasi Hasil Klasterisasi BPR dengan Algoritma SOM .....	66
<b>Tabel 4.27</b>	Bobot <i>Output Neuron</i> SOM Hasil Klasterisasi BPR Terbaik.....	66
<b>Tabel 4.28</b>	Jarak Terhadap Bobot dari Hasil Klasterisasi BPR Terbaik dengan SOM .....	67
<b>Tabel 4.29</b>	Hasil Klasterisasi BPR Terbaik dengan SOM .....	67
<b>Tabel 4.30</b>	Evaluasi Hasil Klasterisasi BPRS dengan Algoritma SOM.....	72
<b>Tabel 4.31</b>	Bobot <i>Output Neuron</i> SOM Hasil Klasterisasi BPRS Terbaik .....	72
<b>Tabel 4.32</b>	Jarak Terhadap Bobot dari Hasil Klasterisasi BPRS Terbaik dengan SOM .....	73
<b>Tabel 4.33</b>	Hasil Klasterisasi BPRS Terbaik dengan SOM.....	73
<b>Tabel 4.34</b>	Perbandingan Nilai Evaluasi Kluster Ketiga Metode .....	74
<b>Tabel 4.35</b>	Interpretasi Hasil Kluster BPR.....	77
<b>Tabel 4.36</b>	Interpretasi Hasil Kluster BPRS .....	79



## DAFTAR LAMPIRAN

<b>Lampiran 1</b> Data Rasio Kinerja Keuangan .....	87
<b>Lampiran 2</b> Data Rasio Kinerja Keuangan yang Distandarisasi .....	89
<b>Lampiran 3</b> Data Lengkap Jarak dari Hasil Klasterisasi BPR Terbaik dengan <i>K-means</i> .....	91
<b>Lampiran 4</b> Data Lengkap Derajat Keanggotaan Hasil Klasterisasi BPR Terbaik dengan <i>Fuzzy C-means</i> .....	93
<b>Lampiran 5</b> Data Lengkap Jarak Terhadap Bobot dari Hasil Klasterisasi BPR Terbaik dengan SOM .....	95
<b>Lampiran 6</b> <i>Script Preprocessing Data</i> .....	97
<b>Lampiran 7</b> <i>Script Analisis Clustering</i> .....	98
<b>Lampiran 8</b> <i>Script Interpretasi Hasil Klasterisasi</i> .....	101
<b>Lampiran 9</b> Surat Pernyataan Data Sekunder .....	103



## DAFTAR SIMBOL

$a_i$	: rerata ketidaksamaan antara objek $i$ dan objek lain pada kluster dimana objek $i$ berada (untuk perhitungan nilai indeks <i>Silhouette</i> )
$\alpha(t)$	: <i>learning rate</i> pada algoritma <i>Self-Organizing Map</i> (SOM)
$b_i$	: nilai minimum dari $d(i, C)$ yang dihitung untuk semua kluster selain dimana objek $i$ berada (untuk perhitungan nilai indeks <i>Silhouette</i> )
$c_j$	: pusat kluster ( <i>centroid</i> ) $j$
$c_j^{(\eta)}$	: pusat kluster ( <i>centroid</i> ) $j$ saat iterasi ke- $\eta$
$c_{jp}$	: pusat kluster ( <i>centroid</i> ) $j$ pada variabel ke- $p$
$C$	: matriks seluruh pusat kluster ( <i>centroid</i> )
$C_{FCM}^*$	: matriks <i>centroid</i> algoritma <i>fuzzy c-means</i> optimal
$C_{KM}^*$	: matriks <i>centroid</i> algoritma <i>k-means</i> optimal
$C^{(\eta)}$	: matriks seluruh pusat kluster ( <i>centroid</i> ) iterasi ke- $\eta$
$CH$	: indeks <i>Calinski-Harabasz</i>
$d_{c_j, x_i}$	: jarak <i>euclidian</i> objek $x_i$ dan <i>centroid</i> $c_j$
$d(i, C)$	: rerata ketidaksamaan antara objek $i$ dan objek lain pada kluster selain dimana objek $i$ berada (untuk perhitungan nilai indeks <i>Silhouette</i> )
$DB$	: indeks <i>Davies-Bouldin</i>
$\varepsilon$	: <i>threshold</i> kriteria pemberhentian algoritma <i>fuzzy c-means</i>
$\eta$	: iterasi dalam algoritma <i>k-means</i> dan <i>fuzzy c-means</i>
$\eta_{max}$	: iterasi maksimal dalam algoritma <i>k-means</i> dan <i>fuzzy c-means</i>
$h_{gs}(t)$	: <i>neighbourhood kernel</i> yang terpusat pada <i>winning neuron</i> SOM
$k$	: banyaknya kluster
$m$	: parameter <i>fuzzification</i> pada algoritma <i>fuzzy c-means</i>
$\mu_C^{(\eta)}$	: matriks derajat keanggotaan saat iterasi ke- $\eta$
$\mu_{c_j}(x_i)$	: derajat keanggotaan objek $x_i$ masuk ke dalam kluster $j$
$M_{ij}$	: jarak <i>euclidean</i> antar <i>centroid</i> (untuk perhitungan nilai indeks <i>Davies-Bouldin</i> )
$n$	: banyaknya data
$n_{c_k}$	: banyak data yang dikategorikan ke kluster $k$
$R_p^2$	: koefisien determinasi saat variabel ke- $p$ diregresikan dengan variabel lain
$sd_p$	: standar deviasi variabel ke- $p$

- $\sigma(t)$  : radius perluasan fungsi *neighbourhood* pada algoritma SOM
- $Sil_i$  : indeks *Silhouette* untuk objek  $i$
- $S_j$  : rata-rata jarak *Euclidean* dari suatu objek di dalam kluster  $j$  terhadap *centroid*-nya (untuk perhitungan nilai indeks *Davies-Bouldin*)
- $t$  : iterasi dalam algoritma SOM
- $T$  : iterasi maksimal dalam algoritma SOM
- $VIF_p$  : *variance inflation factor* variabel ke- $p$
- $w_g$  : *winning neuron* atau vektor bobot terkait dengan *neuron* yang menghasilkan jarak minimum dengan vektor *input*  $x_i$
- $w_s$  : seluruh vektor bobot selain *winning neuron*
- $w_u$  : vektor bobot yang terkait dengan neuron ke- $u$
- $w_{u,p}$  : bobot terkait dengan *neuron* ke-  $u$  yang terkoneksi terhadap variabel ke  $p$  dari vektor *input*  $x_i$
- $x_{i,p}$  : variabel ke- $p$  pada data ke- $i$
- $x_{i,p}^*$  : variabel ke- $p$  pada data ke- $i$  yang telah distandarisasi
- $\bar{x}_p$  : rata-rata variabel ke- $p$
- $X$  : matriks *dataset*

# BAB I PENDAHULUAN

## 1.1. Latar Belakang

Perbankan memiliki pengaruh yang sangat penting dalam ekonomi suatu negara. Sebab fungsi utama perbankan adalah antara lain sebagai penghimpun dan penyalur dana masyarakat yang bertujuan untuk menunjang pelaksanaan pembangunan nasional dalam rangka meningkatkan pemerataan pembangunan dan hasil-hasilnya serta pertumbuhan ekonomi dan stabilitas nasional ke arah peningkatan taraf hidup rakyat banyak. Dalam fungsi penghimpun dana, dilansir dari Statistik Perbankan Indonesia, sumber dana di perbankan per Juni 2024 mencapai nilai 9.825.358 miliar rupiah, yakni mengalami peningkatan sebesar 857.181 miliar rupiah dibanding periode yang sama di tahun sebelumnya. Oleh karena itu, perbankan yang sehat merupakan salah satu indikator optimal tidaknya perekonomian suatu bangsa (Otoritas Jasa Keuangan, 2024a).

Struktur perbankan yang sehat merupakan salah satu faktor pendukung terjaganya stabilitas perekonomian nasional. Berdasarkan Undang-Undang No. 10 Tahun 1998 Tentang Perbankan, struktur perbankan di Indonesia terdiri atas dua jenis bank yakni Bank Umum dan Bank Perekonomian Rakyat (BPR). Sejalan dengan peraturan tersebut, pada Undang-Undang Nomor 21 Tahun 2008 tentang Perbankan Syariah, struktur perbankan syariah terdiri atas dua jenis bank yaitu Bank Umum Syariah dan Bank Pembiayaan Rakyat Syariah (BPRS). BPR dan BPRS merupakan lembaga jasa keuangan yang memiliki peran untuk melayani masyarakat khususnya pada segmen mikro dan kecil. BPR melaksanakan kegiatan usaha secara konvensional, sedangkan BPRS berprinsip syariah, yang mana keduanya dalam kegiatannya tidak memberikan jasa dalam lalu lintas pembayaran (Otoritas Jasa Keuangan, 2020).

Hingga saat ini, keberadaan BPR dan BPRS masih sangat dibutuhkan oleh masyarakat mengingat perbankan jenis ini memiliki karakteristik khusus yang membedakannya dari jenis perbankan lainnya. Karakteristik tersebut meliputi sebaran lokasi yang sebagian besar berada di wilayah kabupaten dan kecamatan, pendekatan pelayanan yang personal atau kekeluargaan, proses pelayanan yang cepat dan sederhana, serta produk dan layanan yang disesuaikan dengan kebutuhan masyarakat di daerahnya. Karakteristik-karakteristik tersebutlah yang membuka peluang besar bagi BPR dan BPRS untuk melakukan ekspansi kegiatan bisnisnya (Kemenkeu RI, 2022).

Namun demikian, BPR dan BPRS memiliki beberapa tantangan dan permasalahan dalam kegiatan bisnisnya, salah satunya adalah rendahnya tingkat likuiditas. Bersumber dari Statistik Perbankan Indonesia, pada Juni 2024, total kredit BPR adalah sejumlah 144.957 miliar rupiah dan total Dana Pihak Ketiga sebesar 139.341 miliar rupiah. Sedangkan di BPRS, total pembiayaan sebesar 17.977 miliar rupiah dengan total Dana Pihak Ketiga sebesar 15.290 miliar rupiah. Data tersebut menunjukkan tingkat persentase total kredit BPR dan total pembiayaan BPRS terhadap masing-masing total DPK masih tinggi sehingga membatasi kemampuan BPR dan BPRS untuk menyalurkan peminjaman atau pembiayaan (Otoritas Jasa Keuangan, 2024a).

Selain itu, dari sisi risiko, tingkat *Non Performing Loan* (NPL) di BPR dan BPRS tercatat lebih tinggi dibandingkan NPL Bank Umum. Pada Juni 2024, NPL BPR adalah sebesar 11,39% dan NPL BPRS sebesar 8,23%. Nilai tersebut melampaui batas rasio NPL yang ditetapkan oleh Bank Indonesia untuk perbankan yakni sebesar 5%. Di sisi lain, NPL Bank Umum Konvensional hanya sebesar 2,26% dan NPL Bank Umum Syariah sebesar 2,04%. Perbedaan besaran rasio tersebut menunjukkan bahwa pinjaman dan pembiayaan di BPR atau BPRS memiliki risiko lebih tinggi dibandingkan dengan bank umum konvensional maupun syariah (Otoritas Jasa Keuangan, 2024b).

Berbagai tantangan dan permasalahan yang dihadapi BPR dan BPRS dapat mengancam keberlanjutan usaha BPR dan BPRS. Sejak Januari hingga April 2024, OJK telah mencabut izin usaha 10 BPR dan/atau BPRS yang selanjutnya juga sudah dilikuidasi oleh LPS (Lembaga Penjamin Simpanan). Oleh karena itu, penting bagi BPR dan BPRS untuk rutin melakukan penilaian tingkat kesehatan perbankan agar BPR dan BPRS mampu mengidentifikasi permasalahan dengan cepat serta mengambil tindak lanjut perbaikan yang sesuai sehingga BPR dan BPRS mampu bertahan di tengah persaingan usaha yang ketat dan kondisi krisis. Berdasarkan POJK Nomor 3 Tahun 2022, penilaian tingkat kesehatan BPR dan BPRS dilakukan berdasarkan empat faktor yaitu profil risiko, tata kelola, rentabilitas, dan permodalan. Faktor profil risiko dinilai secara kuantitatif melalui rasio *Non Performing Loan* (NPL) dan *Loan to Deposit ratio* (LDR), sementara faktor tata kelola diwakili oleh rasio Beban Operasional terhadap Pendapatan Operasional (BOPO) (Kusumawardani, 2014). Untuk faktor rentabilitas, penilaian dilakukan terhadap rasio *Return on Asset* (ROA) serta *Net Interest Margin* (NIM) bagi BPR dan *Net Imbalan* bagi BPRS. Adapun faktor permodalan dinilai melalui rasio Kewajiban Pemenuhan Modal Minimum (KPM) (Otoritas Jasa Keuangan, 2022).

Pengelompokan BPR dan BPRS ke dalam beberapa kategori yang memiliki komponen penilaian yang sama berdasarkan kriteria tingkat kesehatan perbankan, dapat dilakukan menggunakan analisis *clustering*. *Cluster* atau kategori merupakan sebuah kelompok dengan anggota yang memiliki kesamaan yang juga memiliki perbedaan dari kelompok lain (Everitt, dkk., 2011). Algoritma *clustering* memisahkan, memecahkan, atau membagi data ke dalam sejumlah kategori (*cluster*) menurut karakteristik tertentu (Xu dan Wunsch, 2009). Dalam analisis *clustering* terdapat beberapa algoritma yang bisa digunakan, salah satunya ialah *k-means clustering*. Algoritma *k-means* bekerja dengan menemukan pusat dari *cluster* yakni *centroid* dalam data sebanyak iterasi yang dilakukan. Algoritma ini memiliki beberapa kelebihan di antaranya, sederhana untuk diaplikasikan, memiliki kinerja yang relatif cepat, dan mudah beradaptasi dengan data (Yohannes, 2016). Terdapat juga *clustering* dengan algoritma *fuzzy c-means* yang bekerja dengan melakukan perulangan untuk memperbaiki *pusat cluster* dan derajat keanggotaan yang pada awalnya masih belum akurat. Dibandingkan *k-means*, algoritma *fuzzy c-means* memiliki kemungkinan kegagalan untuk kesamaan kelompok yang lebih kecil (Yohannes, 2016). Selain algoritma *k-means* dan *fuzzy c-means*, metode *Self-Organizing Map* (SOM) juga merupakan pendekatan yang banyak digunakan dalam proses *clustering* terutama untuk data dengan dimensi yang kompleks. *Self-Organizing Map* (SOM) termasuk dalam algoritma *unsupervised machine learning* berbasis *neural network* yang mampu mengelompokkan *overlapping* data dan hasil kluster data yang bersifat non linier (Ettaouil, dkk., 2012).

Algoritma *k-means*, *fuzzy c-means*, dan *Self-Organizing Map* (SOM) sering digunakan dalam penelitian dengan metode *clustering* pada berbagai disiplin ilmu. Sebagai contoh, pada penelitian yang dilakukan oleh Setiawan dkk. (2023), dari data 191 rumah sakit di Jakarta, algoritma *k-means* dan *fuzzy c-means* menghasilkan jumlah kelompok yang sama yakni 3 *cluster*. Algoritma *k-means* mengelompokkan data dengan proporsi sebesar 84,82%; 14,66%; dan 0,52%, sedangkan *fuzzy c-means* menghasilkan proporsi pengelompokan sebesar 17,80%; 73,82%; dan 8,38%. Zhao dkk. (2023) dalam penelitiannya membandingkan penerapan metode *Self-Organizing Feature Map* (SOFM), *k-means*, dan *fuzzy c-means* pada *clustering* regionalisasi lingkungan tanah alami di Tiongkok. Hasil penelitian tersebut menunjukkan bahwa algoritma *fuzzy c-means* menghasilkan hasil *clustering* paling optimal dengan terbentuknya 13 *cluster*. Hasil penelitian tersebut sejalan dengan penelitian yang dilakukan oleh Yohannes pada tahun 2016, yang mana algoritma *fuzzy c-means* lebih baik dalam hal komputasi untuk mencari derajat keanggotaan masing-masing *cluster* dalam pengelompokan data. Selain

itu, hasil klusterisasi untuk setiap data dan jumlah *cluster* pada masing-masing algoritma bervariasi sesuai kompleksitasnya.

Mengingat hasil klusterisasi dan jumlah kluster bervariasi pada setiap algoritma, perlu dilakukan evaluasi hasil klusterisasi menggunakan metode validitas kluster. Metode yang digunakan untuk mengevaluasi klusterisasi adalah menghitung indeks validitas klusterisasi yang terdiri atas indeks *Silhouette* (Sil), indeks *Davies-Bouldin* (DB), dan indeks *Calinski-Harabasz* (CH). Ketiga indeks tersebut digunakan pada penelitian Zhao (2023) yang menunjukkan bahwa algoritma *fuzzy c-means* menghasilkan klusterisasi paling optimal yakni sebanyak 13 kluster. Saat terbentuk 13 kluster dengan algoritma *fuzzy c-means*, didapatkan indeks Sil sebesar 0,78; indeks DB sebesar 1,16; dan indeks CH sebesar  $6,77 \times 10^6$ . Di sisi lain, pada penelitian yang dilakukan Putri dan Dwidayati (2021) menunjukkan bahwa *k-means clustering* menghasilkan indeks DB sebesar 1,16 yang mana lebih baik dibanding *fuzzy c-means clustering* yang sebesar 1,74. Oleh karena itu, pemilihan algoritma klusterisasi berdasarkan evaluasi indeks validitas kluster perlu dilakukan untuk memastikan hasil klusterisasi optimal sesuai karakteristik data yang dianalisis.

Dalam bidang keuangan, penelitian dengan metode analisis *clustering* telah dilakukan oleh Puspita dan Pratiwi pada tahun 2017. Penelitian tersebut melakukan *hierarchical clustering* pada BPRS di Indonesia tahun 2013-2016 berdasarkan kinerja keuangan. Penelitian tersebut menghasilkan kesimpulan berupa jumlah *cluster* yang berbeda setiap tahunnya, yakni 3 *cluster* pada 2013 dan 4 *cluster* pada 2014-2016. Selama 4 tahun, *cluster* dengan kinerja keuangan cenderung baik memiliki rata-rata 16 BPRS, dan sebaliknya *cluster* dengan kinerja kurang baik memiliki rata-rata 21 BPRS yang memiliki kelemahan pada rasio BOPO. Penelitian serupa juga pernah dilakukan pada perbankan umum syariah periode 2016-2017. Penelitian yang dilakukan Pristyandini (2018) tersebut menghasilkan 4 *cluster* dengan 7,69% bank termasuk pada *cluster* pertama dengan kategori sangat sehat. Secara spesifik, analisis *clustering* dengan algoritma *k-means* telah dilakukan oleh Guna (2023) untuk mengelompokkan bank umum konvensional di Indonesia. Pada penelitian tersebut dihasilkan jumlah *cluster* sebanyak 3 kategori, yaitu bank kategori sehat, kurang sehat, dan tidak sehat. Terdapat 3 bank yang termasuk *cluster* bank sehat, 9 bank yang termasuk *cluster* bank kurang sehat, dan 32 bank sisanya termasuk dalam *cluster* bank tidak sehat.

Berdasarkan latar belakang yang telah diuraikan sebelumnya, akan dilakukan analisis *clustering* menggunakan algoritma *k-means*, *fuzzy c-means*, dan *Self-Organizing Map* untuk mengelompokkan BPR dan BPRS di wilayah Surabaya Raya yang meliputi kota/kabupaten Gresik, Bangkalan, Mojokerto, Surabaya, Sidoarjo, dan Lamongan. Pengelompokan ini dilakukan dengan menggunakan analisis *clustering* yang dapat menyederhanakan komponen penilaian kesehatan perbankan yang bersumber dari laporan keuangan yang dimiliki tiap BPR dan BPRS. Dalam penelitian ini akan dijelaskan keseluruhan analisis berdasarkan karakteristik tingkat kesehatan perbankan yang diperoleh dari rasio-rasio keuangan perbankan pada triwulan III (September) tahun 2024. Penelitian ini diharapkan dapat memberikan pengetahuan bagi regulator perbankan, akademisi, masyarakat umum, serta pelaku industri dalam memahami kesehatan perbankan BPR dan BPRS sehingga membantu dalam pengambilan keputusan strategis terkait pengelolaan risiko perbankan.

## 1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, rumusan masalah yang akan dibahas dalam penelitian ini adalah,

1. Bagaimana hasil eksplorasi data keuangan perbankan pada BPR dan BPRS di wilayah Surabaya Raya?

2. Bagaimana hasil klasterisasi BPR dan BPRS di wilayah Surabaya Raya berdasarkan kinerja keuangannya dengan algoritma *k-means*?
3. Bagaimana hasil klasterisasi BPR dan BPRS di wilayah Surabaya Raya berdasarkan kinerja keuangannya dengan algoritma *fuzzy c-means*?
4. Bagaimana hasil klasterisasi BPR dan BPRS di wilayah Surabaya Raya berdasarkan kinerja keuangannya dengan algoritma *Self-Organizing Map* (SOM)?
5. Bagaimana hasil evaluasi klasterisasi BPR dan BPRS di wilayah Surabaya Raya menggunakan *Silhouette index* (Sil), *Davies-Bouldin index* (DB), dan *Calinski-Harabasz index* (CH)?

### 1.3. Tujuan

Berdasarkan rumusan masalah yang telah disebutkan, tujuan yang ingin dicapai dalam penelitian ini adalah,

1. Mendapatkan karakteristik data keuangan perbankan pada BPR dan BPRS di wilayah Surabaya Raya.
2. Mendapatkan kelompok *clustering* BPR dan BPRS di wilayah Surabaya Raya berdasarkan kinerja keuangan dengan algoritma *k-means*.
3. Mendapatkan kelompok *clustering* BPR dan BPRS di wilayah Surabaya Raya berdasarkan kinerja keuangan dengan algoritma *fuzzy c-means*.
4. Mendapatkan kelompok *clustering* BPR dan BPRS di wilayah Surabaya Raya berdasarkan kinerja keuangan dengan algoritma *Self-Organizing Map* (SOM).
5. Menentukan kelompok *clustering* terbaik untuk BPR dan BPRS di wilayah Surabaya Raya berdasarkan hasil perhitungan validitas *cluster* menggunakan *Silhouette index* (Sil), *Davies-Bouldin index* (DB), dan *Calinski-Harabasz index* (CH).

### 1.4. Manfaat

Berdasarkan latar belakang yang telah diuraikan, penelitian ini diharapkan memiliki manfaat sebagai berikut,

1. Menambah pengetahuan mengenai analisis *clustering* khususnya metode algoritma *k-means*, *fuzzy c-means*, dan *Self-Organizing Map* (SOM).
2. Menambah pengetahuan tentang *clustering* pada BPR dan BPRS khususnya berdasarkan karakteristik tingkat kesehatan perbankan.
3. Membantu masyarakat umum dalam mempertimbangkan kinerja BPR dan BPRS berdasarkan tingkat kesehatannya.
4. Membantu pemerintah khususnya Otoritas Jasa Keuangan dalam penyempurnaan sistem penilaian tingkat kesehatan BPR dan BPRS.

### 1.5. Batasan Penelitian

Berdasarkan data yang digunakan dalam penelitian ini, batasan masalah pada penelitian ini adalah,

1. BPR dan BPRS yang dianalisis dalam penelitian ini adalah seluruh BPR dan BPRS di wilayah aglomerasi Surabaya Raya yang meliputi kota/kabupaten Gresik, Bangkalan, Mojokerto, Surabaya, Sidoarjo, dan Lamongan yang terdaftar pada laman resmi OJK.
2. Variabel yang digunakan dalam penelitian ini adalah rasio-rasio kinerja keuangan berdasarkan penilaian tingkat kesehatan tiap BPR dan BPRS tahun 2024 dari laporan keuangan yang terlampir pada situs resmi OJK.

## BAB II TINJAUAN PUSTAKA

### 2.1. Hasil Penelitian Terdahulu

Penelitian terdahulu yang dijadikan referensi dalam penelitian ini disajikan pada Tabel 2.1.

**Tabel 2.1** Penelitian Terdahulu

No	Penulis/ Tahun	Judul	Metode	Hasil
1	(Yohannes, 2016)	Analisis Perbandingan Algoritma <i>Fuzzy C-means</i> dan <i>K-means</i>	<i>K-means</i> dan <i>fuzzy c-means clustering</i>	Algoritma <i>k-means</i> lebih cepat dibandingkan dengan algoritma <i>fuzzy c-means</i> dari segi waktu klasterisasi. Sedangkan algoritma <i>fuzzy c-means</i> lebih baik dalam mencari derajat keanggotaan masing-masing <i>cluster</i> dalam pengelompokan data.
2	(Puspita dan Pratiwi, 2016)	Analisis <i>Clustering</i> Berdasarkan Kinerja Keuangan pada Bank Pembiayaan Rakyat Syariah di Indonesia Tahun 2013-2016	<i>Hierarchical cluster</i> dengan <i>within-groups linkage</i>	Melalui analisis <i>clustering</i> , BPRS di Indonesia selama 4 tahun membentuk jumlah <i>cluster</i> yang berbeda, yaitu 3 <i>cluster</i> pada tahun 2013 dan 4 <i>cluster</i> pada tahun 2014-2016.
3	(Pristyandini, 2018)	Analisis <i>Clustering</i> Bank Umum Syariah Berdasarkan Kinerja Keuangan dan Ukuran Perusahaan (Periode 2016-2017)	<i>Hierarchical cluster</i> dengan <i>average linkage</i>	Dari hasil analisis <i>cluster</i> pada Bank Umum Syariah pada periode 2016-2017 terbentuk sebanyak 4 <i>cluster</i> .
4	(Guna, 2023)	Analisis Pengelompokan Bank Umum Konvensional di Indonesia dengan Metode <i>K-means Clustering</i>	<i>K-means clustering</i>	Bank umum konvensional di Indonesia yang dikelompokkan ke dalam tiga <i>cluster</i> yakni bank yang sehat, kurang sehat, dan tidak sehat masing-masing memiliki anggota <i>cluster</i> sebanyak 3 bank, 9 bank, dan 32 bank.
5	(Setiawan, dkk., 2023)	<i>Clustering models for hospitals in Jakarta using fuzzy c-means and k-means</i>	<i>K-means</i> dan <i>fuzzy c-means clustering</i>	Dari 191 rumah sakit, <i>k-means</i> dan FCM menghasilkan jumlah <i>cluster</i> yang sama. <i>K-means</i> membaginya dengan proporsi 84,82%; 14,66%; dan 0,52%, sedangkan FCM membaginya dengan proporsi 17,80%; 73,82%; dan 8,38%.

**Tabel 2.1** Penelitian Terdahulu (Lanjutan)

No	Penulis/ Tahun	Judul	Metode	Hasil
6	(Zhao, dkk., 2023)	<i>Comparison and application of SOFM, fuzzy c-means and k-means clustering algorithms for natural soil environment regionalization in China</i>	<i>SOFM, fuzzy c-means, dan k-means clustering</i>	Berdasarkan analisis perbandingan metode-metode yang digunakan, saat jumlah <i>cluster</i> sebanyak 13, algoritma FCM menghasilkan <i>cluster</i> optimal dengan nilai validitas <i>cluster</i> indeks <i>Davies-Bouldin</i> (DB) sebesar 1,16; indeks <i>Silhouette</i> (Sil) sebesar 0,78; dan indeks <i>Calinski-Harabasz</i> (CH) sebesar $6,77 \times 10^6$ .

## 2.2. Perbankan

Pada dasarnya, bank merupakan tempat penitipan atau penyimpanan uang, pemberi atau penyalur kredit, dan juga perantara di dalam lalu lintas pembayaran (Harahap dan Saraswati, 2020). Pengertian bank menurut Undang-Undang RI No. 10 Tahun 1998 adalah badan usaha yang menghimpun dana dari masyarakat dalam bentuk simpanan dan menyalurkannya kepada masyarakat dalam bentuk kredit dan atau bentuk-bentuk lainnya dalam rangka meningkatkan taraf hidup rakyat banyak. Secara umum, bank memiliki fungsi utama untuk menghimpun dana dari masyarakat dan menyalurkannya kembali kepada masyarakat untuk berbagai tujuan atau sebagai *financial intermediary* (perantara di bidang keuangan) (Harahap dan Saraswati, 2020). Di Indonesia, perbankan sebagai penghimpun dan penyalur dana masyarakat memiliki tujuan untuk menunjang pelaksanaan pembangunan nasional dalam rangka meningkatkan pemerataan pembangunan dan hasil-hasilnya, pertumbuhan ekonomi, dan stabilitas nasional, ke arah peningkatan taraf hidup rakyat banyak (UU RI Nomor 7 Tahun 1992 Tentang Perbankan, 1992).

### 2.2.1. Bank Umum

Berdasarkan Undang-Undang RI No. 10 Tahun 1998, bank dibedakan menjadi dua jenis yakni bank umum dan Bank Perekonomian Rakyat (BPR). Bank umum yang sering disebut juga bank komersial merupakan bank yang melaksanakan kegiatan usaha secara konvensional yang disebut bank umum konvensional atau berdasarkan prinsip syariah yang disebut bank umum syariah. Bank umum dalam kegiatan usahanya memberikan jasa dalam lalu lintas pembayaran. Sifat jasa yang diberikan bank jenis ini adalah umum yang berarti dapat memberikan seluruh jasa perbankan yang ada. Selain itu, wilayah operasi bank umum juga dapat dilakukan di seluruh wilayah. Di Indonesia, bank umum dapat ditinjau pula dari segi kepemilikannya, sebagai contoh Bank Negara Indonesia (BNI), Bank Rakyat Indonesia (BRI), dan Bank Tabungan Negara (BTN) merupakan contoh bank milik pemerintah. Ada juga Bank Danamon, Bank Muamalat, dan Bank Central Asia yang merupakan bank nasional milik swasta (Harahap dan Saraswati, 2020).

### 2.2.2. Bank Perekonomian Rakyat (BPR)

Bank Perekonomian Rakyat atau BPR merupakan bank yang juga melaksanakan kegiatan usaha secara konvensional atau berdasarkan prinsip syariah yang selanjutnya disebut Bank Pembiayaan Rakyat Syariah atau BPRS. Dalam kegiatannya BPR dan BPRS tidak memberikan jasa dalam lalu lintas pembayaran. Sifat jasa yang diberikan bank jenis ini juga terbatas, yang berarti tidak dapat memberikan seluruh jasa perbankan yang ada (Harahap dan Saraswati,

2020). Secara spesifik, hal utama yang membedakan antara Bank Umum dan BPR/BPRS adalah dalam pemberian jasa, BPR/BPRS tidak dapat menerima simpanan berupa giro, tidak dapat ikut serta dalam lalu lintas pembayaran, tidak dapat melakukan kegiatan bisnis dalam bentuk valuta asing, tidak dapat melakukan penyertaan modal dan usaha perasuransian, serta jangkauan kegiatan operasional yang terbatas (Otoritas Jasa Keuangan, 2020). Berdasarkan Statistik Perbankan Indonesia, per Juni 2024 terdapat 1.384 BPR dan 173 BPRS yang tersebar di seluruh wilayah Indonesia. Sebagai contoh, di Kota Surabaya terdapat BPR Danamitra Surya, BPR Surya Artha Utama, BPRS Karya Mugi Sentosa, BPRS Lantabur Tebuireng, serta BPR dan BPRS lainnya (Otoritas Jasa Keuangan, 2024a, 2024b).

### **2.2.3. Prinsip Konvensional dan Syariah**

Selain perbedaan dalam jenis kegiatan operasional, perbankan di Indonesia juga dapat dibedakan berdasarkan metode penentuan harga, yakni prinsip konvensional dan prinsip syariah. Berdasarkan prinsip konvensional, bank menetapkan bunga sebagai harga untuk produk simpanan, deposito, kredit, serta untuk jasa-jasa lainnya menggunakan biaya dalam nominal atau persentase tertentu (*fee based*). Sebaliknya, berdasarkan prinsip syariah, penentuan harga didasarkan pada hukum Islam, sebagai contoh pembiayaan dengan prinsip bagi hasil (*mudharabah*) (Harahap dan Saraswati, 2020). Prinsip hukum Islam tersebut didasarkan pada fatwa yang dikeluarkan oleh lembaga yang memiliki kewenangan dalam penetapan fatwa di bidang syariah. Aspek-aspek yang membedakan perbankan syariah dibanding perbankan konvensional dapat dilihat dari adanya akad dan legalitas, adanya Dewan Pengawas Syariah, penyelesaian sengketa melalui Badan Arbitrase Syariah maupun Pengadilan Agama, pelarangan melakukan bisnis haram, *syubhat*, dan yang menimbulkan *mudharat* bagi pihak lain, serta adanya sistem bagi hasil dalam pengumpulan maupun penyaluran pembiayaan (UU RI Nomor 21 Tahun 2008 Tentang Perbankan Syariah, 2008).

### **2.3. Tingkat Kesehatan Bank**

Kesehatan bank diartikan sebagai kemampuan bank untuk melakukan kegiatan operasional secara normal dan memenuhi semua kewajibannya dengan baik sesuai dengan peraturan yang berlaku (Harahap dan Saraswati, 2020). Secara lebih detail, kesehatan bank mencakup seberapa sehat bank dalam melaksanakan seluruh kegiatan bisnisnya, termasuk kemampuan menghimpun dana dari masyarakat, lembaga lain, dan modal sendiri. Selain itu aspek kesehatan bank juga mencakup kemampuan mengelola dana, menyalurkan dana ke masyarakat, memenuhi kewajiban kepada berbagai pihak, serta memenuhi peraturan perbankan yang berlaku (Harahap dan Saraswati, 2020).

Meninjau betapa pentingnya kesehatan bank dan untuk melaksanakan prinsip kehati-hatian dalam dunia perbankan, diperlukan peraturan tentang kesehatan bank. Bagi BPR dan BPRS, tingkat kesehatan bank wajib dinilai sebanyak dua kali dalam setahun atau secara semesteran sesuai Peraturan Otoritas Jasa Keuangan Nomor 3/POJK.03/2022 tentang Penilaian Tingkat Kesehatan Bank Perekonomian Rakyat dan Bank Pembiayaan Rakyat Syariah. Penilaian tingkat kesehatan BPR dan BPRS dilakukan untuk meningkatkan efektivitas penerapan manajemen risiko dan tata kelola. Peningkatan efektivitas tersebut dilakukan agar BPR dan BPRS mampu mengidentifikasi permasalahan secara lebih dini, melakukan tindak lanjut perbaikan yang sesuai dan lebih cepat, serta bertahan menghadapi persaingan usaha dan kondisi krisis (Otoritas Jasa Keuangan, 2022).

Dalam mencapai tujuan penilaian tingkat kesehatan, manajemen BPR dan BPRS bertanggung jawab penuh dalam memelihara dan/atau meningkatkan tingkat kesehatannya dengan menerapkan prinsip kehati-hatian dan manajemen risiko dalam melaksanakan kegiatan usaha. Di sisi lain, Otoritas Jasa Keuangan (OJK) bertugas mengevaluasi dan menilai tingkat

kesehatan BPR dan BPRS secara berkala. OJK juga perlu melakukan strategi pengawasan yang sesuai untuk memberikan pembinaan dan pengembangan yang tepat berdasarkan kondisi dan permasalahan yang dihadapi oleh BPR dan BPRS (Otoritas Jasa Keuangan, 2022).

Salah satu bentuk strategi pengawasan yang diterapkan OJK adalah menetapkan sistem penilaian tingkat kesehatan berbasis risiko atau metode RGEC. Strategi ini diatur dalam Peraturan Otoritas Jasa Keuangan Nomor 3/POJK.03/2022 tentang Penilaian Tingkat Kesehatan Bank Perekonomian Rakyat dan Bank Pembiayaan Rakyat Syariah. Tingkat kesehatan BPR dan BPRS merupakan hasil penilaian kondisi BPR dan BPRS yang dilakukan terhadap empat aspek penilaian metode RGEC yaitu *risk profile*, *good corporate governance*, *earning*, dan juga *capital*. Penilaian ini sangat berorientasi pada manajemen risiko sehingga mampu memberikan gambaran yang komprehensif mengenai tingkat kesehatan BPR dan BPRS. Hasil penilaian tersebut akan menghasilkan Peringkat Komposit yang merupakan peringkat akhir hasil penilaian tingkat kesehatan BPR dan BPRS. Penetapan peringkat komposit tingkat kesehatan BPR dan BPRS terdiri dari 5 peringkat yaitu Peringkat Komposit 1 (PK-1) yang mencerminkan kondisi BPR dan BPRS yang secara umum sangat sehat, Peringkat Komposit 2 (PK-2) yang mencerminkan kondisi BPR dan BPRS yang secara umum sehat, Peringkat Komposit 3 (PK-3) yang mencerminkan kondisi BPR dan BPRS yang secara umum cukup sehat, Peringkat Komposit 4 (PK-4) yang mencerminkan kondisi BPR dan BPRS yang secara umum kurang sehat, dan Peringkat Komposit 5 (PK-5) yang mencerminkan kondisi BPR dan BPRS yang secara umum tidak sehat (Otoritas Jasa Keuangan, 2022).

### 2.3.1. Profil Risiko (*Risk Profile*)

Penilaian faktor profil risiko merupakan penilaian terhadap risiko inheren dan kualitas penerapan manajemen risiko dalam aktivitas operasional BPR dan BPRS yang mencerminkan sistem pengendalian risiko BPR dan BPRS. Risiko yang dinilai terdiri atas risiko kredit, risiko operasional, risiko kepatuhan, risiko likuiditas, risiko reputasi, dan risiko strategis sesuai dengan peraturan OJK mengenai penerapan manajemen risiko bagi BPR dan BPRS (Otoritas Jasa Keuangan, 2022). Dalam mengukur faktor profil risiko digunakan dua indikator yakni faktor risiko kredit dengan menggunakan rasio *Non Performing Loan* (NPL) serta faktor risiko likuiditas dengan menggunakan *Loan to Deposit Ratio* (LDR) (Kusumawardani, 2014).

#### 1. NPL (*Non Performing Loan*)

NPL merupakan rasio yang digunakan untuk menggambarkan kemampuan bank dalam menyeleksi calon peminjam sehingga terjadinya kredit atau pembiayaan macet dapat dihindari (Ashari, 2021). Rasio NPL diperoleh dengan mengukur perbandingan antara kredit bermasalah atas total kredit. Kredit bermasalah mencakup kredit yang diberikan kepada pihak ketiga bukan bank yang sudah menunggak lebih dari 90 hari. Kredit bermasalah mencakup kredit yang dikategorikan sebagai Kurang Lancar (Kol-3), Diragukan (Kol-4), dan Macet (Kol-5). OJK menentukan rumus penghitungan NPL sebagai berikut,

$$NPL = \frac{(\text{Kredit kualitas Kurang Lancar, Diragukan, dan Macet})}{\text{Total Kredit yang Diberikan}} \times 100\% \quad (2.1)$$

Rasio NPL dikategorikan baik apabila terjaga sebesar 5% (Otoritas Jasa Keuangan, 2019). Dengan demikian, semakin tinggi NPL, semakin tidak sehat bank tersebut (Sudarmanto, dkk., 2021).

#### 2. LDR (*Loan to Deposit Ratio*)

Rasio LDR merupakan rasio yang digunakan untuk mengukur komposisi jumlah kredit yang diberikan dibandingkan dengan jumlah dana masyarakat dan modal sendiri yang digunakan. Rumus yang digunakan untuk menghitung rasio LDR adalah (Otoritas Jasa

Keuangan, 2019),

$$LDR = \frac{\text{Total Kredit yang Diberikan}}{\text{Total Dana Pihak Ketiga bukan bank}} \times 100\% \quad (2.2)$$

Pada persamaan (2.2), definisi total dana pihak ketiga bukan bank adalah seluruh pendanaan yang diperoleh BPR atau BPRS dari pihak ketiga bukan bank yakni tabungan dan deposito. Menurut SEOJK Nomor 1 Tahun 2019, maksimum besarnya *Loan to Deposit Ratio* perbankan yang sehat adalah sebesar 90%. Nilai rasio LDR yang semakin kecil menggambarkan tingkat kesehatan bank yang semakin baik karena menunjukkan kemampuan likuiditas bank yang baik pula (Ashari, 2021).

### 2.3.2. Tata Kelola (*Good Corporate Governance*)

Penilaian faktor tata kelola merupakan penilaian terhadap kualitas manajemen BPR dan BPRS atas penerapan prinsip tata kelola yang baik (Otoritas Jasa Keuangan, 2022). Dalam menilai faktor tata kelola, ukuran yang digunakan adalah rasio Biaya Operasional terhadap Pendapatan Operasional (BOPO) (Kusumawardani, 2014). BOPO menghitung perbandingan antara biaya operasional dengan pendapatan operasional yang dirumuskan sebagai berikut (Otoritas Jasa Keuangan, 2022),

$$BOPO = \frac{\text{Biaya Operasional}}{\text{Pendapatan Operasional}} \times 100\% \quad (2.3)$$

Rasio BOPO dikatakan efisien apabila bernilai kurang dari sama dengan 85% (Otoritas Jasa Keuangan, 2022). Semakin kecil rasio BOPO yang diperoleh, semakin efisien biaya operasional yang dikeluarkan oleh bank yang mana menunjukkan manajemen dan tata kelola yang baik pula (Ashari, 2021).

### 2.3.3. Rentabilitas (*Earnings*)

Penilaian faktor rentabilitas merupakan penilaian terhadap kondisi dan kemampuan BPR dan BPRS dalam menghasilkan laba untuk mendukung permodalan dan kegiatan operasional secara memadai dan berkesinambungan yang meliputi penilaian terhadap kinerja rentabilitas dan tingkat efisiensi operasional BPR dan BPRS. Penilaian terhadap faktor rentabilitas didasarkan pada dua rasio yaitu *Return on Asset* (ROA) dan *Net Interest Margin* (NIM) bagi BPR atau *Net Imbalan* bagi BPRS (Otoritas Jasa Keuangan, 2022).

#### 1. ROA (*Return on Asset*)

*Return on Asset* (ROA) merupakan rasio yang menunjukkan *return* atas jumlah aktiva yang digunakan dalam perusahaan. Selain untuk mengukur efektivitas manajemen dalam mengelola investasi, rasio ini juga menunjukkan produktivitas seluruh dana perusahaan terhadap hasil pengembalian investasi baik dari modal pinjaman maupun modal sendiri (Fitriana, 2024). Rumus yang digunakan untuk menghitung rasio ROA ialah sebagai berikut (Otoritas Jasa Keuangan, 2022),

$$ROA = \frac{\text{Laba sebelum pajak}}{\text{Rata - rata total aset}} \times 100\% \quad (2.4)$$

Laba sebelum pajak pada persamaan (2.4) merupakan laba sebagaimana tercatat dalam laba rugi tahun berjalan yang disetahunkan. Misalkan untuk posisi bulan Juni, akumulasi laba pada posisi tersebut dihitung dengan cara dibagi 6 dan kemudian dikalikan dengan 12. Kemudian dalam persamaan (2.4) juga, rata-rata total aset disesuaikan dengan periode laporan keuangan. Sebagai contoh untuk posisi bulan Juni, dihitung dengan cara menjumlahkan total aset posisi Januari hingga Juni kemudian dibagi dengan 6. Rentabilitas bank dikategorikan sangat baik jika

memiliki nilai rasio ROA lebih dari 2% (Otoritas Jasa Keuangan, 2022). Semakin tinggi nilai ROA yang dimiliki suatu BPR atau BPRS, maka bank tersebut memiliki kemampuan yang tinggi dalam memperoleh laba untuk mendukung permodalan dan kegiatan operasional secara memadai (Puspita dan Pratiwi, 2016).

## 2. NIM (*Net Interest Margin*) atau NI (*Net Imbalan*)

*Net Interest Margin* (NIM) merupakan rasio yang mengukur kemampuan BPR dalam memperoleh keuntungan bersih terkait dengan pembayaran deviden pendapatan bunga bersih dibandingkan dengan rata-rata total aset produktif (Ashari, 2021). Rasio NIM menurut OJK, dihitung dengan rumus sebagai berikut

$$NIM = \frac{\text{Pendapatan bunga bersih}}{\text{Rata-rata total aset produktif}} \times 100\% \quad (2.5)$$

Pendapatan bunga bersih pada persamaan (2.5) dihitung dengan mengurangi pendapatan bunga dengan beban bunga, kemudian hasilnya disetahunkan. Sedangkan rata-rata total aset produktif pada persamaan (2.5) disesuaikan dengan periode laporan keuangan. Misalkan untuk posisi bulan Juni, total aset produktif posisi Januari sampai dengan Juni dijumlahkan kemudian dibagi dengan 6.

Bagi BPRS, rasio *Net Imbalan* (NI) adalah rasio yang digunakan untuk mengukur kemampuan BPRS dalam mengelola aset produktifnya untuk menghasilkan pendapatan dari penyaluran dana bersih (Otoritas Jasa Keuangan, 2022). Menurut OJK, rasio ini diperoleh dengan membagi pendapatan penyaluran dana setelah bagi hasil dikurangi imbalan dan bonus terhadap rata-rata total aset produktif seperti yang dirumuskan sebagai berikut,

$$NI = \frac{(\text{Pendapatan penyaluran dana setelah bagi hasil, imbalan, \& bonus})}{\text{Rata-rata total aset produktif}} \times 100\% \quad (2.6)$$

Dalam rumus tersebut, pendapatan penyaluran dana setelah bagi hasil, imbalan, dan bonus adalah yang disetahunkan atau dalam 12 bulan terakhir. Sedangkan rata-rata total aset produktif yang diperhitungkan juga disesuaikan dengan periode laporan keuangan seperti halnya pada rasio NI. Batas bawah rasio NIM dan NI yang ditetapkan OJK untuk tingkat kesehatan perbankan yang baik adalah sebesar 10% (Otoritas Jasa Keuangan, 2022). Semakin besar rasio ini, maka terdapat peningkatan pendapatan bunga atau penyaluran dana atas aset produktif yang dikelola sehingga kemungkinan bank dalam kondisi bermasalah semakin kecil (Pristyandini, 2018).

### 2.3.4. Permodalan (*Capital*)

Penilaian faktor permodalan merupakan penilaian terhadap kecukupan modal BPR dan BPRS yang mencerminkan dukungan keuangan dalam pelaksanaan aktivitas BPR dan BPRS untuk menyerap potensi kerugian saat ini dan waktu mendatang. Penilaian faktor permodalan dari segi aspek kuantitatif merupakan penilaian terhadap komponen rasio Kewajiban Pemenuhan Modal Minimum (KPMM). Rasio KPMM merupakan rasio perbandingan modal dengan aktiva tertimbang menurut risiko untuk menilai seberapa jauh aktiva bank mengandung risiko ikut dibiayai dari modal bank. Rasio KPMM dapat dihitung dengan rumus sebagai berikut,

$$KPMM = \frac{\text{Modal inti + modal pelengkap}}{\text{Aktiva Tertimbang Menurut Risiko (ATMR)}} \times 100\% \quad (2.7)$$

Modal inti, modal pelengkap, dan ATMR pada persamaan (2.7) mengacu pada Peraturan Otoritas Jasa Keuangan mengenai kewajiban penyediaan modal minimum dan pemenuhan modal inti minimum BPR dan BPRS. Kondisi permodalan bank dikategorikan baik jika

mempunyai rasio KPMM minimal sebesar 15% atas Aset Tertimbang Menurut Risiko (ATMR) (Otoritas Jasa Keuangan, 2022).

#### 2.4. Preprocessing Data

Sebagian besar data mentah yang berasal dari sebuah *database*, biasanya belum terproses terlebih dahulu, tidak lengkap, dan *noisy*. Misalnya, sebuah data mentah bisa saja berisi variabel yang tidak relevan, *missing values*, *outlier*, atau bentuk data yang tidak cocok untuk metode *data mining*. Data mentah perlu menjalani *preprocessing* dalam bentuk *data cleaning* dan *data transformation* supaya tujuan analisis *data mining* dapat tercapai. Salah satu tujuan utama melakukan *preprocessing* adalah meminimalkan informasi yang tidak berguna dari model yang dihasilkan (Larose, 2005).

Variabel pada data mentah cenderung memiliki rentang yang sangat bervariasi antara satu variabel dengan variabel lainnya. Untuk beberapa algoritma pada metode *data mining*, perbedaan rentang tersebut akan menyebabkan variabel dengan rentang yang lebih besar cenderung memiliki pengaruh yang terlalu berlebihan terhadap hasil yang akan diperoleh. Oleh karenanya dalam metode *data mining*, data dengan variabel numerik harus dinormalkan (*normalized*) untuk menstandarisasi besar pengaruh tiap variabel terhadap hasil. Ada beberapa metode untuk melakukan normalisasi data, salah satu yang paling umum adalah dengan *z-score standarization*. *Z-score standarization* dilakukan dengan melihat perbedaan nilai antara suatu variabel dan rata-ratanya. Kemudian, perbedaan tersebut diskalakan dengan standar deviasi dari variabel tersebut pula. Rumus perhitungan *z-score standarization* untuk suatu variabel adalah sebagai berikut,

$$x_{i_p}^* = \frac{x_{i_p} - \bar{x}_p}{sd_p} \quad (2.8)$$

dengan

$\bar{x}_p$  : rata-rata seluruh  $x_i$  pada variabel ke- $p$ , yang dihitung dengan rumus

$$\bar{x}_p = \frac{(x_{1_p} + x_{2_p} + \dots + x_{n_p})}{n} \quad (2.9)$$

$sd_p$  : standar deviasi seluruh  $x_i$  pada variabel ke- $p$ , yang dihitung dengan rumus

$$sd_p = \sqrt{\frac{\sum_{i=1}^n (x_{i_p} - \bar{x}_p)^2}{n - 1}} \quad (2.10)$$

dimana  $n$  adalah banyaknya data. Pada persamaan (2.8)  $x_{i_p}$  merupakan nilai variabel yang asli dan  $x_{i_p}^*$  adalah nilai variabel yang telah distandarisasi (Larose, 2005).

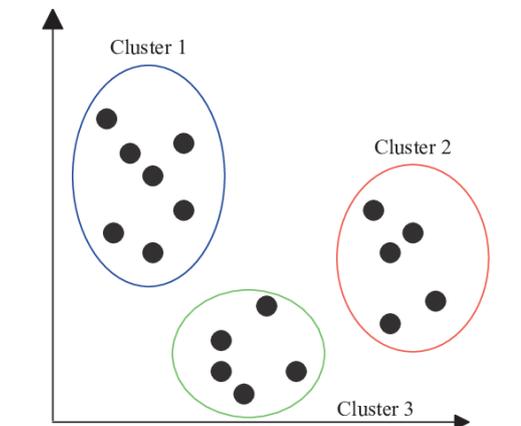
#### 2.5. Analisis Clustering

Analisis *clustering* merupakan istilah dalam *unsupervised learning* untuk sebuah prosedur yang mengelompokkan data ke dalam kelompok-kelompok tertentu. Pada sebagian besar penggunaan analisis *clustering*, akan dicari partisi dalam data sehingga tiap individu atau objek akan masuk ke dalam satu *cluster* saja (Everitt, dkk., 2011). Data yang sering menerapkan analisis *clustering* adalah data multivariat dengan ukuran matriks  $n \times p$  yang terdiri atas nilai variabel-variabel yang menggambarkan setiap individu yang akan dikelompokkan.

$$X = \begin{bmatrix} x_{1_1} & x_{1_2} & \dots & x_{1_p} \\ x_{2_1} & \dots & \dots & \dots \\ \vdots & \vdots & \vdots & \vdots \\ x_{n_1} & \dots & \dots & x_{n_p} \end{bmatrix} \quad (2.11)$$

$x_{n_p}$  dalam  $X$  merupakan nilai variabel ke- $p$  pada data ke- $n$ . Analisis *clustering* digunakan untuk

mengelompokkan data ke sejumlah kelompok kecil (*cluster*) yang terdiri atas objek-objek yang mirip satu sama lain tetapi berbeda dari objek-objek dalam *cluster* lain (Everitt, dkk., 2011). Dengan demikian, ketika hasil analisis *clustering* diplot secara geometris, objek-objek dalam kluster yang sama akan saling berdekatan dan objek-objek dalam kluster yang berbeda akan saling berjauhan (Hair, dkk., 2014, p. 481).



**Gambar 2.1** Ilustrasi Hasil Analisis *Clustering*  
(Fang, dkk., 2023)

Secara umum, metode-metode dalam analisis kluster dapat dibedakan menjadi dua jenis berdasarkan konsep utama perhitungannya, yakni metode *hierarchical clustering* dan *non-hierarchical clustering*. Dalam metode *hierarchical clustering*, pada awalnya setiap objek dalam dataset dianggap berada pada kluster yang terpisah-pisah. Kemudian akan dilakukan penggabungan kluster yang paling mirip secara berulang dan bertahap yang mana akan membentuk kluster yang lebih besar. Metode ini memiliki karakteristik unik yang dapat menggabungkan kluster yang lebih kecil menjadi kluster yang lebih besar (pendekatan *bottom-up*) atau memecah kluster yang lebih besar menjadi kluster yang lebih kecil (pendekatan *top-down*). Untuk menentukan anggota-anggota sebuah kluster atau seberapa terkait dua objek data dengan *hierarchical clustering*, dapat ditentukan dengan beberapa metode seperti jarak *Euclidean*, jarak *Manhattan*, ataupun kesamaan kosinus. Sedangkan pada *non-hierarchical clustering*, metode dibagi lagi menjadi sub-sub metode seperti *partitioning method*, *model-based clustering*, *graph-based method*, dan *density-based method*. Oleh karena itu, *non-hierarchical clustering* memiliki algoritma yang lebih bervariasi untuk menentukan hasil pengelompokannya (Khan, dkk., 2019).

## 2.6. Asumsi Multikolinearitas

Analisis *clustering* bukan teknik inferensi statistik yang menilai parameter dari sampel sebagai representasi populasi. Sebaliknya, analisis *clustering* merupakan metode untuk mengukur karakteristik struktural dari sebuah *dataset*. Dalam melakukan analisis *clustering*, terdapat indikasi yang harus diperhatikan yakni multikolinearitas antar variabel. Multikolinearitas dalam analisis multivariat menyebabkan dampak sebenarnya dari variabel multikolinear sulit dibedakan. Multikolinearitas sebagai pembobotan secara implisit memengaruhi analisis. Oleh karena itu, perlu dilakukan pemeriksaan apakah variabel yang digunakan dalam analisis kluster mengalami indikasi multikolinearitas (Hair, dkk., 2014, p. 499-500).

Untuk mengetahui adanya multikolinearitas diperlukan pemeriksaan nilai  $R^2$  yang dihasilkan dari regresi tiap variabel satu sama lain. Hubungan antar variabel dapat dinilai dengan menghitung *variance inflation factor* (VIF). *Variance inflation factor* untuk variabel ke- $p$  dirumuskan sebagai berikut,

$$VIF_p = \frac{1}{(1-R_p^2)}, p = 1, \dots, \text{banyaknya variabel} \quad (2.12)$$

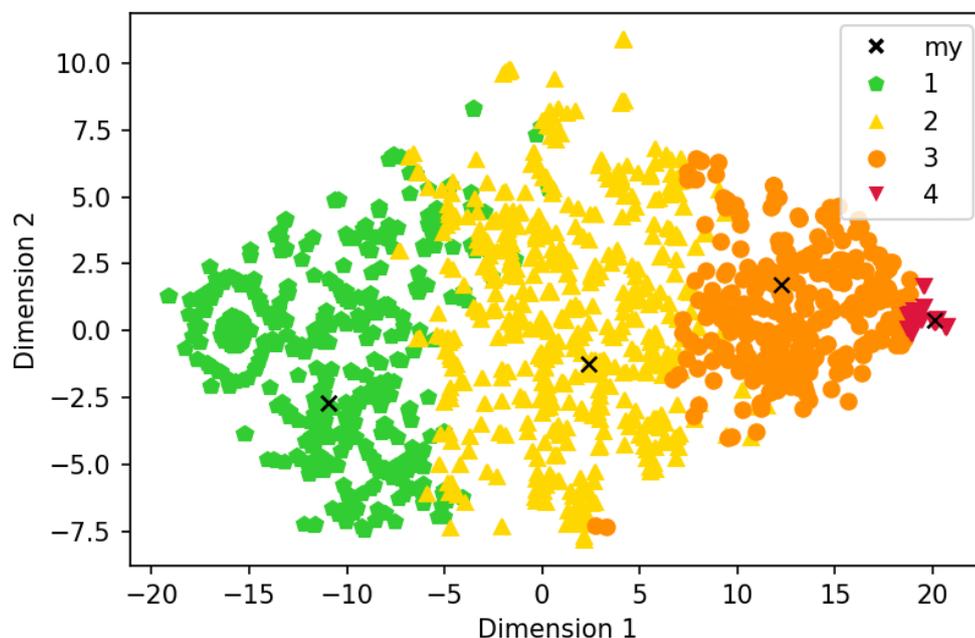
dengan  $R_p^2$  adalah nilai koefisien determinasi saat variabel-variabel diregresikan satu sama lain.  $R^2$  pada persamaan (2.12) didefinisikan dengan persamaan,

$$R^2 = \frac{ESS}{TSS} = \frac{\hat{\beta}_1 \sum y_i x_{i_1} + \hat{\beta}_2 \sum y_i x_{i_2} + \dots + \hat{\beta}_{p-1} \sum y_i x_{i_{p-1}}}{\sum y_i^2} \quad i = 1, \dots, n \quad (2.13)$$

dengan  $ESS$  adalah *explained sum of squares*,  $TSS$  adalah *total sum of squares*,  $\hat{\beta}$  adalah koefisien regresi,  $x_i$  adalah variabel yang dijadikan prediktor,  $y_i$  adalah variabel yang dijadikan respon, serta  $n$  adalah banyaknya objek dalam *dataset* (Gujarati, 2003). Jika suatu variabel memiliki hubungan linear yang kuat dengan variabel lain, nilai  $R^2$  akan mendekati 1 dan  $VIF_p$  akan bernilai besar pula. Nilai VIF lebih dari 10 sering dianggap sebagai indikasi bahwa data memiliki masalah kolinearitas (Chatterjee dan Hadi, 2012, p. 249-250). Jika terindikasi terjadi multikolinieritas, pengurangan jumlah variabel atau penggunaan ukuran jarak yang mempertimbangkan multikolinieritas dapat dilakukan (Hair, dkk., 2014, p. 500).

## 2.7. K-means Clustering

*K-means* merupakan algoritma *non-hierarchical clustering* yang bekerja dengan membagi data ke sejumlah kluster yang telah ditentukan sebelumnya. Kemudian, secara berulang, algoritma ini akan membagi kembali data hingga beberapa kriteria numerik terpenuhi. Kriteria tersebut berkaitan dengan tujuan dari dilakukannya algoritma ini yaitu meminimalkan jarak data satu sama lain pada kluster yang sama dan memaksimalkan jarak antar kluster (Hair, dkk., 2014, p. 507).



**Gambar 2.2** Contoh Visualisasi *Clustering* dengan Algoritma *K-means* (Lobner dkk., 2016)

Pengelompokan dengan algoritma ini dibangun berdasarkan konsep *centroid* yakni titik imajiner dalam ruang data yang mewakili pusat tiap kluster. *K-means* berupaya meminimalkan jarak kuadrat rata-rata antara objek-objek dalam kluster dengan pusat klasternya. Pengelompokan dengan algoritma *k-means* bertujuan untuk mengumpulkan serangkaian objek serupa dalam suatu kluster untuk menemukan sebuah pola yang menjadi dasar pengelompokan (Bigdeli, dkk., 2022).

Algoritma *k-means* membagi dataset  $\mathbf{X}$  yang didefinisikan sebagai

$$\mathbf{X} = [\mathbf{x}_1 \quad \mathbf{x}_2 \quad \dots \quad \mathbf{x}_n]^T \subset \mathbb{R}^p \quad (2.14)$$

yang terdiri atas beberapa objek yang didefinisikan sebagai vektor  $\mathbf{x}_i$  dengan persamaan

$$\mathbf{x}_i = [x_{i_1} \quad x_{i_2} \quad \dots \quad x_{i_p}]^T \in \mathbb{R}^p; i = 1, \dots, n \quad (2.15)$$

ke dalam kluster dengan menetapkan setiap objek hanya dikategorikan ke satu kluster. Pada persamaan (2.14) dan (2.15),  $p$  adalah dimensi dari vektor  $\mathbf{x}_i$ ,  $n$  adalah banyaknya objek dalam dataset, dan  $T$  mewakili matriks *transpose*. Tujuan utama dari algoritma ini disusun atas dasar permasalahan pengelompokan yang dinyatakan sebagai permasalahan optimasi persamaan sebagai berikut,

$$\mathbf{C}_{KM}^* = \arg \left( \min_{\mathbf{C} \in \mathbb{R}^{pk}} V(\mathbf{C}) \right), V(\mathbf{C}) = \sum_{j=1}^k \sum_{i=1}^{n_{c_j}} d_{c_j, x_i}^2; \mathbf{x}_i \in c_j \quad (2.16)$$

dengan  $n_{c_j}, j = 1, \dots, k$  adalah total objek yang dikategorikan ke kluster  $c_j$ . Notasi  $\eta$  akan digunakan seterusnya untuk iterasi-iterasi yang akan digunakan dalam algoritma.  $\eta = 1, \dots, \eta_{max}$  yang mana  $\eta_{max}$  adalah jumlah iterasi maksimal yang harus ditentukan terlebih dahulu.  $\mathbf{C}_{KM}^* \in \mathbb{R}^{pk}$  merupakan solusi untuk permasalahan optimasi atau disebut juga matriks *centroid* optimal.  $\mathbf{C}$  pada persamaan (2.16) adalah *centroid* untuk seluruh kluster yang didefinisikan dengan matriks *centroid* berikut,

$$\mathbf{C} = [c_1 \quad c_2 \quad \dots \quad c_k]^T \in \mathbb{R}^{pk}. \quad (2.17)$$

$c_j$  pada persamaan (2.17) merupakan *centroid* yang didefinisikan sebagai berikut,

$$c_j = [c_{j_1} \quad c_{j_2} \quad \dots \quad c_{j_p}]^T \in \mathbb{R}^p; j = 1, \dots, k \quad (2.18)$$

dimana elemen vektor pada persamaan tersebut berarti pusat kluster ke- $j$  pada variabel ke- $p$ . Langkah-langkah dalam melakukan *k-means clustering* adalah sebagai berikut (Borlea, dkk., 2021),

1. Menginisiasi indeks iterasi  $\eta = 1$  dan jumlah kluster sebanyak  $k$ .
2. Menentukan matriks *centroid*  $\mathbf{C}^{(1)}$  yang merupakan nilai awal dari solusi persamaan (2.16). Solusi persamaan tersebut akan dinyatakan dalam persamaan

$$\mathbf{C}^{(1)} = [c_1^{(1)} \quad c_2^{(1)} \quad \dots \quad c_k^{(1)}]^T \in \mathbb{R}^{pk}. \quad (2.19)$$

3. Menghitung jarak  $d_{c_j, x_i}$  untuk tiap kombinasi objek  $\mathbf{x}_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan sebagai berikut,

$$d_{c_j, x_i} = \sqrt{(x_{i_1} - c_{j_1})^2 + (x_{i_2} - c_{j_2})^2 + \dots + (x_{i_p} - c_{j_p})^2}. \quad (2.20)$$

4. Menetapkan semua objek data ke salah satu  $k$  kluster berdasarkan jarak yang dihitung pada langkah 3. Suatu objek  $\mathbf{x}_i$  akan ditetapkan ke kluster  $c_j^{(\eta)}$  yang memiliki letak *centroid* terdekat terhadap objek  $\mathbf{x}_i$  dengan persamaan sebagai berikut,

$$c_j^{(\eta)} = \left\{ \mathbf{x}_n \mid d_{c_j, x_n} \leq d_{c_i, x_n}, \forall i = 1, \dots, k \right\}. \quad (2.21)$$

5. Setelah objek-objek dalam *dataset* ditetapkan ke seluruh  $k$  kluster, jumlah total  $n_{c_j}^{(\eta)}$  dari objek-objek yang dikelompokkan ke kluster  $c_j^{(\eta)}$  dihitung sebagai *cardinal* dari kluster  $c_j^{(\eta)}$  dengan rumus,

$$n_{c_j}^{(\eta)} = |c_j^{(\eta)}|, j = 1, \dots, k. \quad (2.22)$$

6. Menghitung *centroid* baru untuk iterasi selanjutnya berdasarkan nilai rata-rata dari semua objek *dataset* yang termasuk dalam kluster tertentu. Langkah ini dilakukan dengan rumus sebagai berikut,

$$\mathbf{c}_j^{(\eta+1)} = \frac{1}{n_{c_j}^{(\eta)}} \sum_{x_i \in c_j^{(\eta)}} \mathbf{x}_i, j = 1, \dots, k \quad (2.23)$$

dan nyatakan matriks *centroid*  $\mathbf{C}^{(\eta+1)}$  yang akan digunakan pada iterasi selanjutnya menggunakan persamaan sebagai berikut,

$$\mathbf{C}^{(\eta+1)} = [\mathbf{c}_1^{(\eta+1)} \quad \mathbf{c}_2^{(\eta+1)} \quad \dots \quad \mathbf{c}_k^{(\eta+1)}]^T \in \mathbb{R}^{pk}. \quad (2.24)$$

7. Menguji apakah algoritma *k-means* telah menemukan hasil yang optimal dengan kriteria pemberhentian. Kriteria pemberhentian yang pertama mengecek apakah nilai matriks *centroid* telah berubah atau hasil pengelompokan telah berubah setelah dua iterasi berturut-turut. Kriteria pertama ini dapat diketahui dengan mengecek persamaan berikut,

$$\mathbf{C}^{(\eta+1)} = \mathbf{C}^{(\eta)} \quad (2.25)$$

Jika kriteria persamaan (2.25) tersebut terpenuhi maka algoritma sudah selesai dan solusi untuk persamaan (2.16) adalah nilai  $\mathbf{C}^{(\eta+1)}$  yang didapatkan terakhir kali seperti pada persamaan sebagai berikut,

$$\mathbf{C}_{KM}^* = \mathbf{C}^{(\eta+1)}. \quad (2.26)$$

Sebaliknya, jika kriteria persamaan (2.26) tidak terpenuhi, dilakukan pengecekan untuk kriteria kedua. Kriteria ini menunjukkan bahwa jumlah maksimal iterasi telah tercapai seperti pada persamaan berikut,

$$\eta = \eta_{max}. \quad (2.27)$$

Jika kriteria pada persamaan (2.27) terpenuhi, algoritma telah selesai dan solusi untuk persamaan (2.16) diberikan pada persamaan (2.26). Dalam kondisi lain, jika kedua kriteria sama-sama tidak terpenuhi, iterasi baru akan dilakukan yakni mengganti  $\eta$  menjadi  $\eta + 1$  dan langkah *clustering* diulangi dari langkah ke-3.

*K-means* merupakan algoritma *clustering* klasik yang juga salah satu representasi *unsupervised learning*. *K-means* banyak digunakan di berbagai bidang karena idenya sederhana, efisiensinya tinggi, dan penerapannya yang mudah. Akan tetapi *k-means clustering* memiliki kelemahan berupa kurangnya kemampuan menentukan jumlah kluster, memilih *centroid* awal, dan juga mendeteksi *outlier* (Chong, 2021).

## 2.8. Fuzzy C-means Clustering

Algoritma *fuzzy c-means* yang selanjutnya disebut FCM merupakan jenis algoritma *unsupervised learning* yang memiliki konsep bahwa semakin dekat data dengan pusat kluster, semakin besar juga derajat keanggotaan data tersebut terhadap kluster itu (Alam, dkk., 2019). Salah satu keunggulan menerapkan algoritma FCM adalah setiap objek dalam *dataset* memiliki derajat antara 0 sampai 1 dalam keanggotaan suatu kluster sehingga memperbolehkan suatu data berada pada lebih dari satu kluster (Bora dan Gupta, 2014). Secara lebih spesifik, dengan dataset  $\mathbf{X}$  yang terdiri atas beberapa objek, objek tersebut didefinisikan sebagai vektor  $\mathbf{x}_i$  seperti pada persamaan (2.15). Dalam menjalankan algoritma ini, terdapat beberapa langkah yang harus dilakukan secara iteratif terhadap *dataset* sampai mendapatkan kluster akhir yang dirumuskan pada persamaan (2.28).

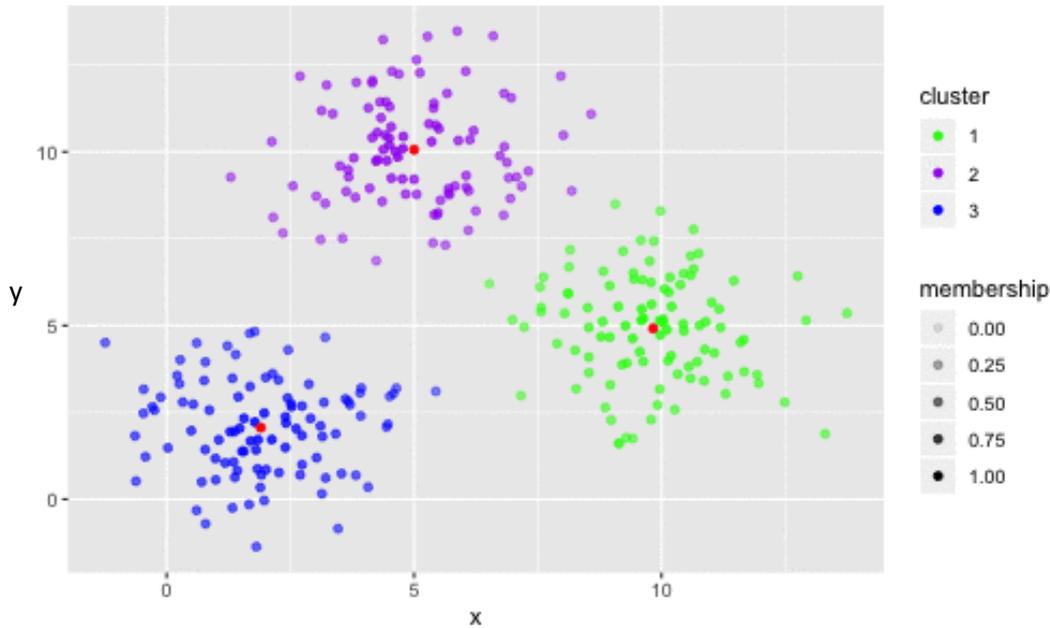
$$\mathbf{C}_j = \left\{ \left( \mathbf{c}_j, \mu_{c_j}(\mathbf{x}_i) \right) \mid i = 1, \dots, n \right\}, j = 1, \dots, k, \quad (2.28)$$

Pada persamaan (2.28)  $k$  adalah banyaknya kluster dan  $n$  adalah banyaknya objek dalam *dataset*.  $\mathbf{c}_j$  adalah pusat kluster atau *centroid* yang didefinisikan dengan persamaan (2.18).

$\mu_{c_j}(x_i)$  adalah derajat keanggotaan sebuah objek  $x_i$  ke dalam kluster  $c_j$  yang dirumuskan dengan persamaan

$$\mu_{c_j}(x_i) = \frac{\left(\frac{1}{d_{c_j, x_i}}\right)^{\frac{2}{m-1}}}{\sum_{j=1}^k \left(\frac{1}{d_{c_j, x_i}}\right)^{\frac{2}{m-1}}} \quad (2.29)$$

dengan  $m > 1$  adalah parameter *fuzzification* dan  $d_{c_j, x_i}$  adalah jarak antara objek  $x_i$  dan *centroid*  $c_j$  yang dirumuskan dengan menggunakan persamaan (2.20). *Centroid* untuk seluruh kluster dikelompokkan dalam matriks *centroid*  $\mathbf{C}$  seperti pada persamaan (2.17) (Borlea, dkk., 2021).



**Gambar 2.3** Contoh Visualisasi FCM Clustering

Tujuan utama dari algoritma FCM adalah untuk meminimalisir varians intra kluster. Algoritma ini dapat diformulasikan dalam masalah *clustering* dengan optimasi seperti pada persamaan berikut (Borlea, dkk., 2021),

$$\mathbf{C}_{FCM}^* = \arg \left( \min_{\mathbf{C} \in \mathbb{R}^{p \times k}} V(\mathbf{C}) \right), V(\mathbf{C}) = \sum_{i=1}^n \sum_{j=1}^k \left\{ \mu_{c_j}(x_i)^m d_{c_j, x_i}^2 \right\} \quad (2.30)$$

Langkah-langkah dalam melakukan FCM *clustering* adalah sebagai berikut (Borlea, dkk., 2021),

1. Menginisiasi indeks iterasi  $\eta = 1$  dan jumlah kluster  $k$ .
2. Menentukan matriks *centroid*  $\mathbf{C}^{(1)}$  yaitu nilai awal dari solusi persamaan (2.30). Solusi persamaan tersebut akan dinyatakan dalam persamaan (2.19).
3. Menghitung jarak  $d_{c_j, x_i}$  untuk tiap kombinasi objek  $x_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan (2.20).
4. Membangun matriks keanggotaan  $\mu_{\mathbf{C}}^{(\eta)}$ , seperti pada persamaan berikut

$$\mu_{\mathbf{C}}^{(\eta)} = \begin{bmatrix} \mu_{c_1}^{(\eta)}(x_1) & \dots & \mu_{c_k}^{(\eta)}(x_1) \\ \vdots & \ddots & \vdots \\ \mu_{c_1}^{(\eta)}(x_n) & \dots & \mu_{c_k}^{(\eta)}(x_n) \end{bmatrix} \in \mathbb{R}^{n \times k} \quad (2.31)$$

yang mana elemen  $\mu_{c_j}^{(\eta)}(\mathbf{x}_i)$  pada matriks tersebut dihitung dengan persamaan (2.29).

5. Menghitung *centroid* baru untuk iterasi selanjutnya dengan persamaan sebagai berikut,

$$\mathbf{c}_j^{(\eta+1)} = \frac{\sum_{i=1}^n \left\{ \left[ \mu_{c_j}^{(\eta)}(\mathbf{x}_i) \right]^m \mathbf{x}_i \right\}}{\sum_{i=1}^n \left[ \mu_{c_j}^{(\eta)}(\mathbf{x}_i) \right]^m} \quad (2.32)$$

dengan  $n$  adalah banyaknya objek dalam *dataset*. Kemudian, matriks *centroid* baru yang telah diperoleh dalam langkah ini dapat dituliskan kembali dengan persamaan (2.24).

6. Membangun matriks keanggotaan baru untuk iterasi selanjutnya  $\mu_c^{(\eta+1)}$  sebagaimana dilakukan pada langkah ke-4.
7. Menguji apakah algoritma FCM telah menemukan hasil yang optimal dengan kriteria pemberhentian. Proses algoritma sudah selesai jika satu atau kedua kriteria pemberhentian terpenuhi. Kriteria pemberhentian yang pertama mengecek apakah matriks keanggotaan berubah dalam *threshold* dengan lebar kurang dari  $\varepsilon < 0$  setelah dua iterasi berturut-turut. Kriteria pertama ini dituliskan dalam persamaan berikut (Bora dan Gupta, 2014),

$$\left| \mu_c^{(\eta+1)} - \mu_c^{(\eta)} \right| < \varepsilon \quad (2.33)$$

Jika kriteria persamaan (2.33) tersebut terpenuhi, algoritma sudah selesai dan solusi untuk persamaan (2.30) adalah sebagai berikut,

$$\mathbf{C}_{FCM}^* = \mathbf{C}^{(\eta+1)} \quad (2.34)$$

Sebaliknya, jika kriteria persamaan (2.33) tidak terpenuhi, dilakukan pengecekan kriteria kedua yang dinyatakan dalam persamaan (2.27). Jika kriteria kedua telah terpenuhi, algoritma sudah selesai dan solusi untuk persamaan (2.30) diberikan pada persamaan (2.34). Terakhir, jika kedua kriteria tersebut tidak terpenuhi, iterasi baru akan dilakukan dengan mengganti  $\eta$  menjadi  $\eta + 1$  dan langkah *clustering* diulangi dari langkah ke-5.

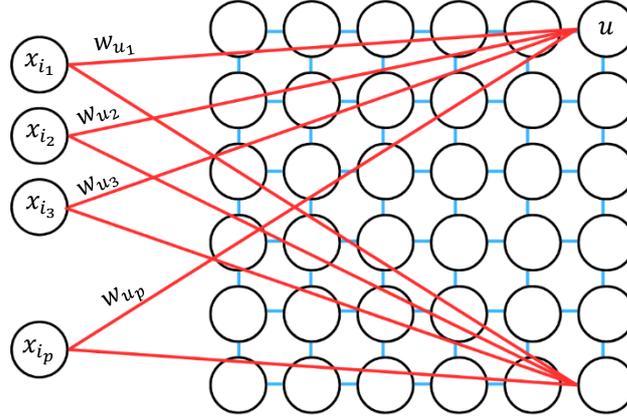
Karena keterlibatan perhitungan derajat keanggotaan *fuzzy* dalam klusterisasi, algoritma FCM membutuhkan waktu yang lebih lama jika dibandingkan dengan *k-means*. Akan tetapi, FCM merupakan algoritma yang cocok dalam kemampuan pengenalan pola, data yang tidak lengkap, dan yang mengandung informasi campuran. Selain itu, algoritma FCM juga lebih baik dalam hal komputasi untuk mencari derajat keanggotaan masing-masing kluster dalam pengelompokan data (Yohannes, 2016).

## 2.9. Self-Organizing Map (SOM) Clustering

SOM *neural network* pertama kali dicetuskan berdasarkan proses pembelajaran yang terjadi di jaringan syaraf (*neuron*) pada otak manusia (Kohonen, 1982). SOM sebagai pemetaan 2D, mengubah proyeksi nonlinear dari data multivariat  $p$ -dimensi ke tampilan berdimensi rendah. Tidak seperti algoritma partisi berdasarkan pusat kluster, SOM menggunakan algoritma berbasis *competition mechanism* (Kohonen, 2013). Jaringan SOM menggabungkan *input layer* dengan *competitive layer* dari *processing neurons* yang biasanya tersusun sebagai *grid* dua dimensi (Ghaseminezhad dan Karami, 2011).

Seperti yang terlihat pada Gambar 2.4, jaringan SOM merupakan *array* dari  $\mathbf{U} = u_x \times u_y$  *processing neurons*. Saat  $\mathbf{U}$  *neuron* tersebut disusun pada *grid* bidang, jaringan tersebut disebut dua dimensi, karena jaringan SOM memetakan vektor *input* berdimensi tinggi menjadi bidang dengan dua dimensi. Pada jaringan pada Gambar 2.4, vektor *input*  $\mathbf{x}_i$  memiliki dimensi yang tetap sebanyak  $p$ . Komponen  $p$  dari vektor *input*  $\mathbf{x}_i$  ( $x_{i_1}, x_{i_2}, \dots, x_{i_p}$ ) terhubung ke setiap *neuron* dalam *grid* tersebut. Bobot sinaptik  $w_{u_1}$  didefinisikan sebagai koneksi dari neuron ke- $u$  terhadap komponen ke-1 dari vektor *input*  $\mathbf{x}_i$ . Dengan demikian, vektor  $p$ -dimensi  $\mathbf{w}_u$  dari

bobot sinaptik dikaitkan dengan setiap neuron  $u$  (Ghaseminezhad & Karami, 2011).



**Gambar 2.4** Struktur Dasar Jaringan SOM

Algoritma SOM bekerja pada dua fase yakni fase pencocokan kesamaan dan fase adaptasi bobot. Awalnya, bobot ditentukan dengan nilai acak yang kecil dan pola disajikan ke *input nodes* jaringan. Selama fase pencocokan kesamaan, dilakukan perhitungan *Euclidean distance* antara *input* dan bobot yang berkaitan dengan *output neuron*. Selanjutnya, *output neuron*  $u$  yang memiliki jarak minimum di antara  $\mathbf{U}$  *output* terpilih menjadi *winning neuron*. Pada fase kedua, dilakukan modifikasi bobot dari *input nodes* ke *winning neuron* (Ghaseminezhad dan Karami, 2011). Algoritma jaringan SOM dapat dilakukan dengan langkah-langkah sebagai berikut (Bigdeli, dkk., 2022; Ghaseminezhad dan Karami, 2011),

1. Menetapkan *learning iteration number* yakni  $t = 0$  dan jumlah iterasi ( $T$ ). Kemudian inisiasi juga seluruh bobot dengan nilai acak yang kecil.
2. Ketika iterasi ( $t$ ) lebih kecil daripada  $T$ , lakukan langkah 3 hingga langkah 6.
3. Memilih vektor *input*  $\mathbf{x}_i$  secara acak.
4. Menghitung jarak *Euclidean* antara vektor *input* dan seluruh *neuron*.
5. Menentukan neuron mana yang bobotnya menghasilkan jarak paling minimal dengan vektor *input* menggunakan persamaan

$$\|\mathbf{x}_i - \mathbf{w}_g\| = \min_s \|\mathbf{x}_i - \mathbf{w}_s\|, s = 1, \dots, \text{banyaknya } \textit{output neuron} \quad (2.35)$$

dengan  $g$  mewakili *winning neuron* dan  $\mathbf{w}_g$  adalah vektor bobot terdekat terhadap  $\mathbf{x}_i$ .

6. Memperbarui vektor bobot *winning neuron*  $\mathbf{w}_g$  dan seluruh vektor bobot selain *winning neuron*  $\mathbf{w}_s$  untuk membuat vektor *input*  $\mathbf{x}_i$  semakin mendekat ke *winning neuron*. Pada iterasi berikutnya,  $\mathbf{w}_g$  dan  $\mathbf{w}_s$  dapat dirumuskan ulang dengan,

$$\mathbf{w}_g(t+1) = \mathbf{w}_g(t) + \alpha(t) (\mathbf{x}_i - \mathbf{w}_g(t)) \quad (2.36)$$

$$\mathbf{w}_s(t+1) = \mathbf{w}_s(t) + h_{gs}(t)^* (\mathbf{x}_i - \mathbf{w}_s(t)), s = 1, \dots, \text{banyaknya } \textit{output neuron} \quad (2.37)$$

$\alpha(t)$  pada persamaan (2.36) menunjukkan *learning rate* yang dianggap sebagai *degree of matching* dan berkurang secara monoton seiring waktu. Sedangkan  $h_{gs}(t)$  pada persamaan (2.37) adalah *neighbourhood kernel* yang berpusat pada *winner neuron* dan  $t$  menunjukkan waktu. *Kernel* tersebut dapat dirumuskan dengan persamaan sebagai berikut,

$$h_{gs}(t) = \alpha(t) \times \exp\left(-\frac{\|\mathbf{w}_g - \mathbf{w}_s\|^2}{2 \times \sigma(t)^2}\right) \quad (2.38)$$

dengan  $\sigma(t)$  adalah radius perluasan fungsi *neighbourhood* (Bigdeli, dkk., 2022).

7. Selanjutnya, tetapkan  $t = t + 1$  dan jika  $t < T$ , kembali ke langkah 3. Sebaliknya jika  $t > T$ , algoritma sudah selesai.

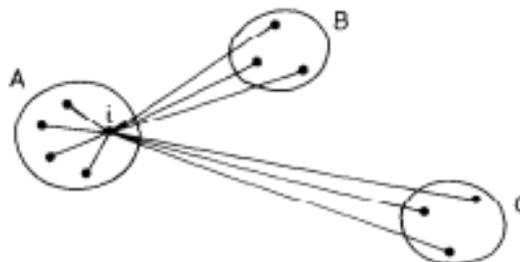
Dengan menyajikan semua vektor *input* ke seluruh *neuron*, *winning neuron* dan *neuron-neuron* tetangganya akan tertarik ke posisi yang sesuai distribusi data sebenarnya. Proses yang dilakukan secara terus menerus dan berulang-ulang akan membentuk *grid neuron* yang lebih baik mewakili distribusi data. *Neuron* yang berdekatan pada *grid* mewakili bagian data yang serupa. Dengan demikian, struktur topologi yang diperoleh dengan peta dua dimensi dapat mewakili distribusi data yang multidimensi (Yang, dkk., 2024).

## 2.10. Kriteria Evaluasi *Cluster*

Tantangan utama dalam melakukan *unsupervised learning* adalah mengevaluasi hasil pengelompokan dan menentukan jumlah kelompok yang optimal (Sugar dan James, 2003). Hal itu dikarenakan *unsupervised learning* tidak memiliki hasil yang benar dan tepat yang bisa dijadikan sebagai tolak ukur (Fraley dan Raftery, 2002). Oleh karenanya perlu dilakukan evaluasi kluster berdasarkan indeks validitas *clustering*. Terdapat beberapa indeks yang dapat digunakan untuk mengevaluasi model *clustering* yakni *Silhouette index* (Sil), *Davies-Bouldin index* (DB), ataupun *Calinski-Harabasz index* (CH).

### 2.10.1. *Silhouette Index* (Sil)

Indeks *Silhouette* digunakan untuk mengetahui seberapa baik pengelompokan objek-objek ke dalam kluster yang kompak tetapi terpisah dengan jelas. Dalam menghitung indeks ini, hanya memerlukan dua hal yakni klusterisasi yang kita peroleh dan kumpulan semua kedekatan antar objek.



**Gambar 2.5** Ilustrasi Perhitungan Indeks *Silhouette* pada Objek  $i$  pada Kluster A (Rousseeuw, 1987)

Untuk tiap objek  $i$  yang terkategori pada kluster A,  $Sil_i$  didefinisikan terlebih dahulu dalam kasus ketidaksamaan yang dilakukan dengan prosedur sebagai berikut (Rousseeuw, 1987),

1. Menghitung rerata ketidaksamaan ( $a_i$ ) antara  $i$  dan semua objek lain di kluster A. Perhitungan dilakukan dengan menghitung panjang rata-rata semua garis dalam kluster A seperti contoh pada Gambar 2.5.
2. Menghitung rerata ketidaksamaan  $d(i, C)$  antara  $i$  dan semua objek lain di kluster C. Perhitungan dilakukan dengan menghitung panjang rata-rata semua garis yang bergerak dari objek  $i$  ke kluster C seperti contoh pada Gambar 2.5.
3. Setelah menghitung  $d(i, C)$  untuk semua kluster selain A, dipilih angka terkecil yang merupakan nilai minimum dari  $d(i, C)$  yang akan disebut sebagai  $b_i$ .
4. Menghitung nilai indeks *Sil* untuk objek  $i$  dengan persamaan sebagai berikut (Rousseeuw, 1987),

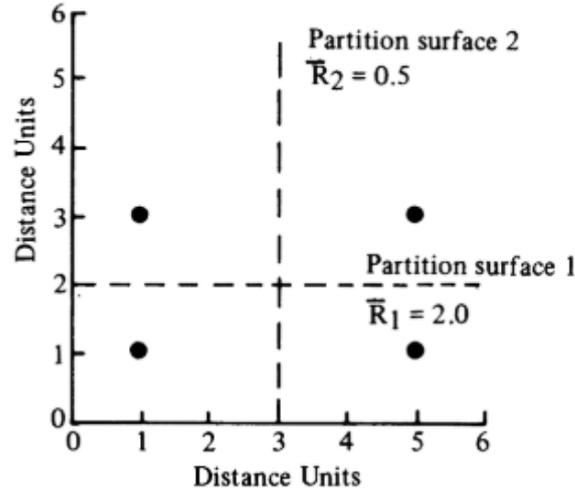
$$Sil_i = \frac{(b_i - a_i)}{\max(a_i, b_i)} \quad (2.39)$$

Nilai  $Sil_i$  dari persamaan (2.39) akan bernilai di antara -1 hingga 1. Saat  $Sil_i$  bernilai mendekati 1, artinya objek  $i$  telah dikelompokkan dengan tepat. Sebaliknya  $Sil_i$  yang bernilai

negatif menunjukkan bahwa objek berada di dalam kluster yang salah. Untuk satu set data,  $Sil$  dihitung dengan rata-rata  $Sil_i$  semua objek. Semakin dekat jarak antara objek dalam kategori yang sama, semakin jauh pula jarak antara objek dalam kategori yang berbeda, semakin tinggi nilai indeks *Silhouette*-nya (Zhao, dkk., 2023).

### 2.10.2. Davies-Bouldin Index (DB)

Indeks *Davies-Bouldin* menyatakan fungsi atas dua istilah yakni identifikasi minimalisasi variansi antar kluster dan maksimalisasi jarak intra kluster.



**Gambar 2.6** Ilustrasi Validitas *Cluster* dengan Indeks *Davies-Bouldin* (Davies dan Bouldin, 1979)

Indeks *Davies-Bouldin* didefinisikan dalam persamaan sebagai berikut,

$$DB = \frac{1}{k} \sum_{i=1}^k R_i \quad (2.40)$$

dengan  $R_i$  adalah nilai maksimum dari  $R_{ij}$  saat  $i \neq j$  dan  $j = 1, \dots, k$ .  $R_{ij}$  didefinisikan dengan persamaan sebagai berikut,

$$R_{ij} = \frac{S_i + S_j}{M_{ij}}. \quad (2.41)$$

$S_i$  pada persamaan (2.41) didefinisikan sebagai

$$S_i = \frac{1}{n_k} \sum_{j=1}^{n_k} (|x_j - c_i|^a)^{\frac{1}{a}} \quad (2.42)$$

dengan  $n_k$  adalah jumlah objek dalam kluster ke- $k$ ,  $c_i$  adalah *centroid* dari kluster ke- $i$ , dan  $|x_j - c_i|$  adalah jarak dari data ke- $j$  dalam kluster  $i$  terhadap *centroid*-nya. Sedangkan  $M_{ij}$  pada persamaan (2.41) didefinisikan dengan persamaan sebagai berikut,

$$M_{ij} = \left( |c_i - c_j|^b \right)^{\frac{1}{b}}, i \neq j \quad (2.43)$$

$M_{ij}$  pada persamaan (2.43) merupakan rumus jarak metrik *Minkowski*. Pada penelitian ini digunakan nilai  $b = 2$  untuk persamaan (2.43) dan  $a = 1$  untuk persamaan (2.42). Saat  $b = 2$ ,  $M_{ij}$  menjadi jarak *Euclidean* antar *centroid*. Begitu pula  $S_i$  pada persamaan (2.42), saat  $a = 1$ ,  $S_i$  menjadi rata-rata jarak *Euclidean* dari objek di dalam kluster  $i$  terhadap *centroid*-nya.  $DB$  pada persamaan (2.40) merupakan ukuran kesamaan tiap kluster dengan kluster yang paling mirip. Oleh karena itu, kluster terbaik adalah kluster yang meminimalkan nilai kesamaan ini. Dengan demikian, semakin kecil nilai indeks *Davies-Bouldin*, semakin kecil pula jarak dalam kluster yang sama dan semakin besar jarak antar kluster-kluster (Davies dan Bouldin, 1979).

### 2.10.3. Calinski-Harabasz Index (CH)

Indeks *Calinski-Harabasz* mengukur kekompakan suatu kluster dan pemisahan himpunan data dengan menghitung kuadrat jarak antara setiap objek pada kluster dan pusat kluster (Caliński dan Harabasz, 1974). Indeks ini diperoleh dari rasio derajat pemisahan dan kekompakan sehingga semakin besar CH, semakin dekat satu kluster itu sendiri dan semakin tersebar kluster-kluster yang berbeda. Persamaan untuk menghitung indeks CH dilakukan dengan menggunakan rumus sebagai berikut,

$$CH = \frac{SSB}{SSW} \times \frac{(n-k)}{(k-1)} \quad (2.44)$$

dengan  $n$  adalah jumlah objek dalam *dataset* dan  $k$  adalah jumlah kluster. Pada persamaan (2.44),  $SSW$  adalah *sum of squares within cluster*, sedangkan  $SSB$  ialah *sum of squares between cluster*. Keduanya didefinisikan dalam persamaan sebagai berikut,

$$SSW = \sum_{i=1}^k \sum_{j=1}^{n_k} \|\mathbf{x}_{jk} - \mathbf{c}_k\|^2 \quad (2.45)$$

$$SSB = \sum_{i=1}^k n_k \times \|\mathbf{c}_k - \mathbf{c}\|^2 \quad (2.46)$$

Pada persamaan (2.45)  $x_{jk}$  merupakan objek ke- $j$  pada kluster ke- $k$ ,  $n_k$  adalah jumlah objek pada kluster ke- $k$ , dan  $\mathbf{c}_k$  adalah *centroid* kluster ke- $k$ . Sedangkan  $\mathbf{c}$  pada persamaan (2.46) adalah *centroid* dataset atau vektor yang terdiri dari nilai rerata tiap variabel dalam dataset (Ros, dkk., 2023).

*“Halaman ini sengaja dikosongkan”*

## BAB III METODOLOGI PENELITIAN

### 3.1. Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah semua BPR dan BPRS di wilayah Surabaya Raya yang meliputi Kabupaten Gresik, Kabupaten Bangkalan, Kabupaten dan Kota Mojokerto, Kota Surabaya, Kabupaten Sidoarjo, serta Kabupaten Lamongan (Putra dan Salim, 2022). BPR dan BPRS di wilayah tersebut dibatasi harus memiliki laporan keuangan yang telah dipublikasikan pada laman resmi Otoritas Jasa Keuangan (OJK) pada kanal “Laporan Publikasi Keuangan Perbankan”. Laporan publikasi yang digunakan adalah laporan kualitas aset produktif BPR dan laporan rasio keuangan BPRS. Data yang digunakan adalah rasio-rasio keuangan dari masing-masing laporan periode triwulan ketiga atau bulan September 2024. Satuan yang digunakan pada keenam rasio tersebut ialah persen. Enam rasio keuangan per BPR atau BPRS yang telah disebutkan pada bab sebelumnya akan dikumpulkan menjadi data 6 variabel indikator tingkat kesehatan BPR dan BPRS dengan penjelasan tiap indikator tertera pada Tabel 3.1.

**Tabel 3.1** Variabel Indikator Tingkat Kesehatan BPR dan BPRS

Variabel	Keterangan
$x_1$	<i>Non Performing Loan (NPL)</i> BPR dan BPRS
$x_2$	<i>Loan to Deposit Ratio (LDR)</i> BPR dan BPRS
$x_3$	Beban Operasional Pendapatan Operasional (BOPO) BPR dan BPRS
$x_4$	<i>Return on Asset (ROA)</i> BPR dan BPRS
$x_5$	<i>Net Interest Margin (NIM)</i> BPR atau <i>Net Imbalan (NI)</i> BPRS
$x_6$	Kewajiban Penyediaan Modal Minimum (KPMM) BPR dan BPRS

Sebanyak 91 BPR dan BPRS di kota dan kabupaten di wilayah Surabaya Raya merupakan objek pengamatan yang digunakan pada penelitian ini. Secara rinci, 91 BPR dan BPRS tersebut terbagi ke kota dan kabupaten di wilayah Surabaya Raya sebagaimana tertera pada Tabel 3.2.

**Tabel 3.2** Rekap Jumlah BPR dan BPRS di Surabaya Raya

Nama Daerah	Jumlah BPR	Jumlah BPRS	Total
Kabupaten Gresik	11	2	13
Kabupaten Bangkalan	2	-	2
Kabupaten Mojokerto	8	-	8
Kota Mojokerto	2	-	2
Kota Surabaya	16	1	17
Kabupaten Sidoarjo	39	3	42
Kabupaten Lamongan	6	1	7
<b>Total</b>	<b>84</b>	<b>7</b>	<b>91</b>

Tiap BPR dan BPRS memiliki rasio-rasio keuangan yang akan diteliti sebagaimana struktur data penelitian pada Tabel 3.3 di bawah ini. Data  $x_{1,1,1}$  pada Tabel 3.3 menunjukkan data rasio NPL pada BPR/BPRS ke-1 yang berada di Kabupaten Gresik.

Tabel 3.3 Struktur Data Penelitian

Kota/Kabupaten (o)	Nama BPR/BPRS (n)	(p)					
		NPL	LDR	BOPO	ROA	NIM/NI	KPMM
Kabupaten Gresik	1	$x_{1,1,1}$	$x_{1,1,2}$	$x_{1,1,3}$	$x_{1,1,4}$	$x_{1,1,5}$	$x_{1,1,6}$
	2	$x_{1,2,1}$	$x_{1,2,2}$	$x_{1,2,3}$	$x_{1,2,4}$	$x_{1,2,5}$	$x_{1,2,6}$
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	12	$x_{1,12,1}$	$x_{1,12,2}$	$x_{1,12,3}$	$x_{1,12,4}$	$x_{1,12,5}$	$x_{1,12,6}$
	13	$x_{1,13,1}$	$x_{1,13,2}$	$x_{1,13,3}$	$x_{1,13,4}$	$x_{1,13,5}$	$x_{1,13,6}$
Kabupaten Bangkalan	1	$x_{2,1,1}$	$x_{2,1,2}$	$x_{2,1,3}$	$x_{2,1,4}$	$x_{2,1,5}$	$x_{2,1,6}$
	2	$x_{2,2,1}$	$x_{2,2,2}$	$x_{2,2,3}$	$x_{2,2,4}$	$x_{2,2,5}$	$x_{2,2,6}$
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Kabupaten Sidoarjo	1	$x_{6,1,1}$	$x_{6,1,2}$	$x_{6,1,3}$	$x_{6,1,4}$	$x_{6,1,5}$	$x_{6,1,6}$
	2	$x_{6,2,1}$	$x_{6,2,2}$	$x_{6,2,3}$	$x_{6,2,4}$	$x_{6,2,5}$	$x_{6,2,6}$
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	41	$x_{6,41,1}$	$x_{6,41,2}$	$x_{6,41,3}$	$x_{6,41,4}$	$x_{6,41,5}$	$x_{6,41,6}$
	42	$x_{6,42,1}$	$x_{6,42,2}$	$x_{6,41,3}$	$x_{6,42,4}$	$x_{6,42,5}$	$x_{6,42,6}$
Kabupaten Lamongan	1	$x_{7,1,1}$	$x_{7,1,2}$	$x_{7,1,3}$	$x_{7,1,4}$	$x_{7,1,5}$	$x_{7,1,6}$
	2	$x_{7,2,1}$	$x_{7,2,2}$	$x_{7,2,3}$	$x_{7,2,4}$	$x_{7,2,5}$	$x_{7,2,6}$
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	6	$x_{7,6,1}$	$x_{7,6,2}$	$x_{7,6,3}$	$x_{7,6,4}$	$x_{7,6,5}$	$x_{7,6,6}$
	7	$x_{7,7,1}$	$x_{7,7,2}$	$x_{7,7,3}$	$x_{7,7,4}$	$x_{7,7,5}$	$x_{7,7,6}$

### 3.2. Langkah Analisis

Metode analisis yang digunakan dalam penelitian ini adalah analisis *clustering* dengan algoritma *k-means*, *fuzzy c-means*, dan *Self-Organizing Map* (SOM) untuk mengetahui pengelompokan BPR dan BPRS berdasarkan tingkat kesehatan bank. Analisis dilakukan dengan bantuan perangkat lunak *R Studio* dan *Microsoft Excel*. Langkah-langkah analisis yang dilakukan dalam penelitian ini adalah sebagai berikut,

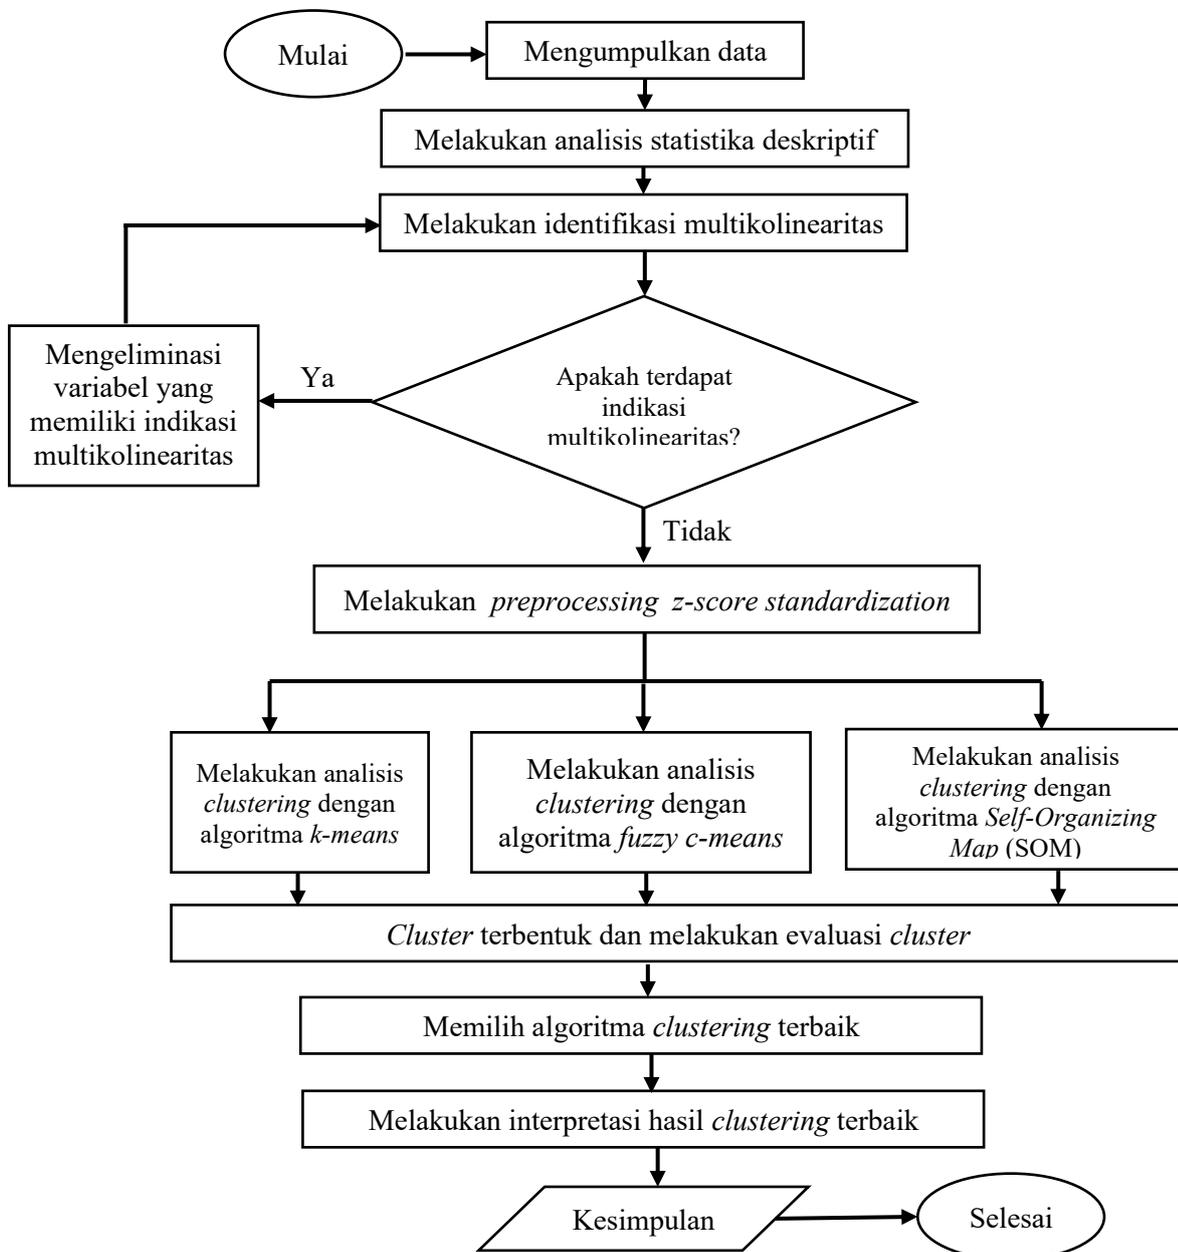
1. Studi literatur pada referensi berupa buku, jurnal, maupun laman resmi pemerintahan sesuai dengan permasalahan penelitian dan metode yang digunakan.
2. Mengumpulkan data. Dalam penelitian ini dilakukan pengumpulan data sekunder. Data berupa rasio keuangan merupakan hasil olahan laporan keuangan BPR dan BPRS periode September 2024. Data sekunder berasal dari laman resmi Otoritas Jasa Keuangan (OJK) untuk mendapatkan data secara lengkap.
3. Melakukan analisis statistika deskriptif atas data yang diperoleh untuk mengetahui karakteristik data. Analisis deskriptif yang dilakukan meliputi perhitungan rata-rata, standar deviasi, nilai maksimum, dan nilai minimum. Sedangkan secara visualisasi, analisis statistika deskriptif dilakukan dengan membuat plot histogram dari masing-masing variabel.
4. Melakukan identifikasi multikolinearitas untuk menguji ada atau tidaknya tingkat korelasi antar variabel yang diujikan. Apabila ditemukan gejala multikolinearitas pada suatu variabel, variabel tersebut akan dieliminasi.

5. Melakukan *preprocessing data* dengan membuat data olahan hasil normalisasi *z-score standardization*. Kedua *dataset* yakni data asli dan data hasil standarisasi, masing-masing akan dilakukan analisis *clustering* sesuai langkah ke-6 hingga 8.
6. Membentuk *cluster* dengan algoritma *k-means*.
  - a. Menginisiasi indeks iterasi  $\eta = 1$ , iterasi maksimum  $\eta_{max} = 100$  (Borlea dkk., 2021; Yohannes, 2016), dan jumlah kluster  $k$  sebanyak 3, 4, dan 5 untuk pengelompokan BPR, serta jumlah kluster  $k$  sebanyak 2 dan 3 untuk pengelompokan BPRS (Otoritas Jasa Keuangan, 2022; Puspita dan Pratiwi, 2016).
  - b. Menginisiasi matriks *centroid*  $\mathbf{C}^{(1)}$  yang didefinisikan dengan persamaan (2.19).
  - c. Menghitung jarak  $d_{c_j, x_i}$  menggunakan persamaan (2.20).
  - d. Menetapkan setiap objek ke kluster sesuai persamaan (2.21).
  - e. Menghitung *centroid* baru untuk setiap kluster yakni  $\mathbf{c}_j^{(\eta+1)}$  dengan persamaan (2.23).
  - f. Mengecek kriteria pemberhentian algoritma sesuai persamaan (2.25) dan (2.27). Jika memenuhi, hasil kluster sesuai dengan persamaan (2.26). Jika tidak,  $\eta$  ditambah secara bertahap dan tahapan diulang dari langkah ke-c.
7. Membentuk *cluster* dengan algoritma *fuzzy c-means*.
  - a. Menginisiasi parameter awal yang terdiri dari indeks iterasi  $\eta = 1$ , iterasi maksimum  $\eta_{max} = 100$ , *fuzziness parameter*  $m = 2$ , dan nilai konvergensi  $\varepsilon = 10^{-5}$  (Borlea dkk., 2021; Yohannes, 2016). Selain itu ditentukan pula jumlah kluster  $k$  sebanyak 3, 4, dan 5 untuk pengelompokan BPR, serta jumlah kluster  $k$  sebanyak 2 dan 3 untuk pengelompokan BPRS (Otoritas Jasa Keuangan, 2022; Puspita dan Pratiwi, 2016).
  - b. Menginisiasi matriks *centroid*  $\mathbf{C}^{(1)}$  yang didefinisikan pada persamaan (2.19).
  - c. Menghitung jarak  $d_{c_j, x_i}$  menggunakan persamaan (2.20).
  - d. Membangun matriks keanggotaan  $\mu_c^{(\eta)}$  seperti pada persamaan (2.31).
  - e. Menghitung *centroid* baru untuk setiap kluster yakni  $\mathbf{c}_j^{(\eta+1)}$  dengan persamaan (2.32).
  - f. Membangun matriks keanggotaan baru untuk iterasi selanjutnya  $\mu_c^{(\eta+1)}$  sebagaimana dilakukan pada langkah ke-d.
  - g. Mengecek kriteria pemberhentian algoritma sesuai persamaan (2.33) dan (2.27). Jika memenuhi, hasil kluster sesuai dengan persamaan (2.34). Jika tidak,  $\eta$  ditambah secara bertahap dan tahapan diulang dari langkah ke-e.
8. Membentuk *cluster* dengan algoritma *Self-Organizing Map* (SOM).
  - a. Membentuk *grid output neuron* SOM sesuai dengan jumlah kluster yang akan dibentuk. Misalkan akan membentuk pengelompokan dengan 4 kluster, *grid output neuron* SOM akan dibentuk dari dimensi  $u_x = 2$  dan dimensi  $u_y = 2$  sehingga *output neuron* akan berjumlah 4.
  - b. Membuat model SOM dengan parameter berikut: *learning iteration number* ( $t = 0$ ), jumlah iterasi ( $T = 200$ ), *learning rate* ( $\alpha = 0,9$ ), serta *neighbourhood radius* ( $\text{radius} = 0,5$ ) (Bigdeli dkk., 2022).
  - c. Menginisiasi matriks bobot yang berkaitan dengan *output neuron* dengan nilai yang acak. Ukuran matriks disesuaikan dengan jumlah *grid* SOM dan jumlah variabel.
  - d. Memilih vektor input  $\mathbf{x}_i$  secara acak.
  - e. Menghitung jarak *Euclidean* antara vektor *input* dan seluruh *output neuron*.
  - f. Menentukan *output neuron* mana yang bobotnya menghasilkan jarak paling minimal dengan vektor *input* menggunakan persamaan (2.35). *Output neuron* yang terpilih disebut juga dengan *winning neuron*.

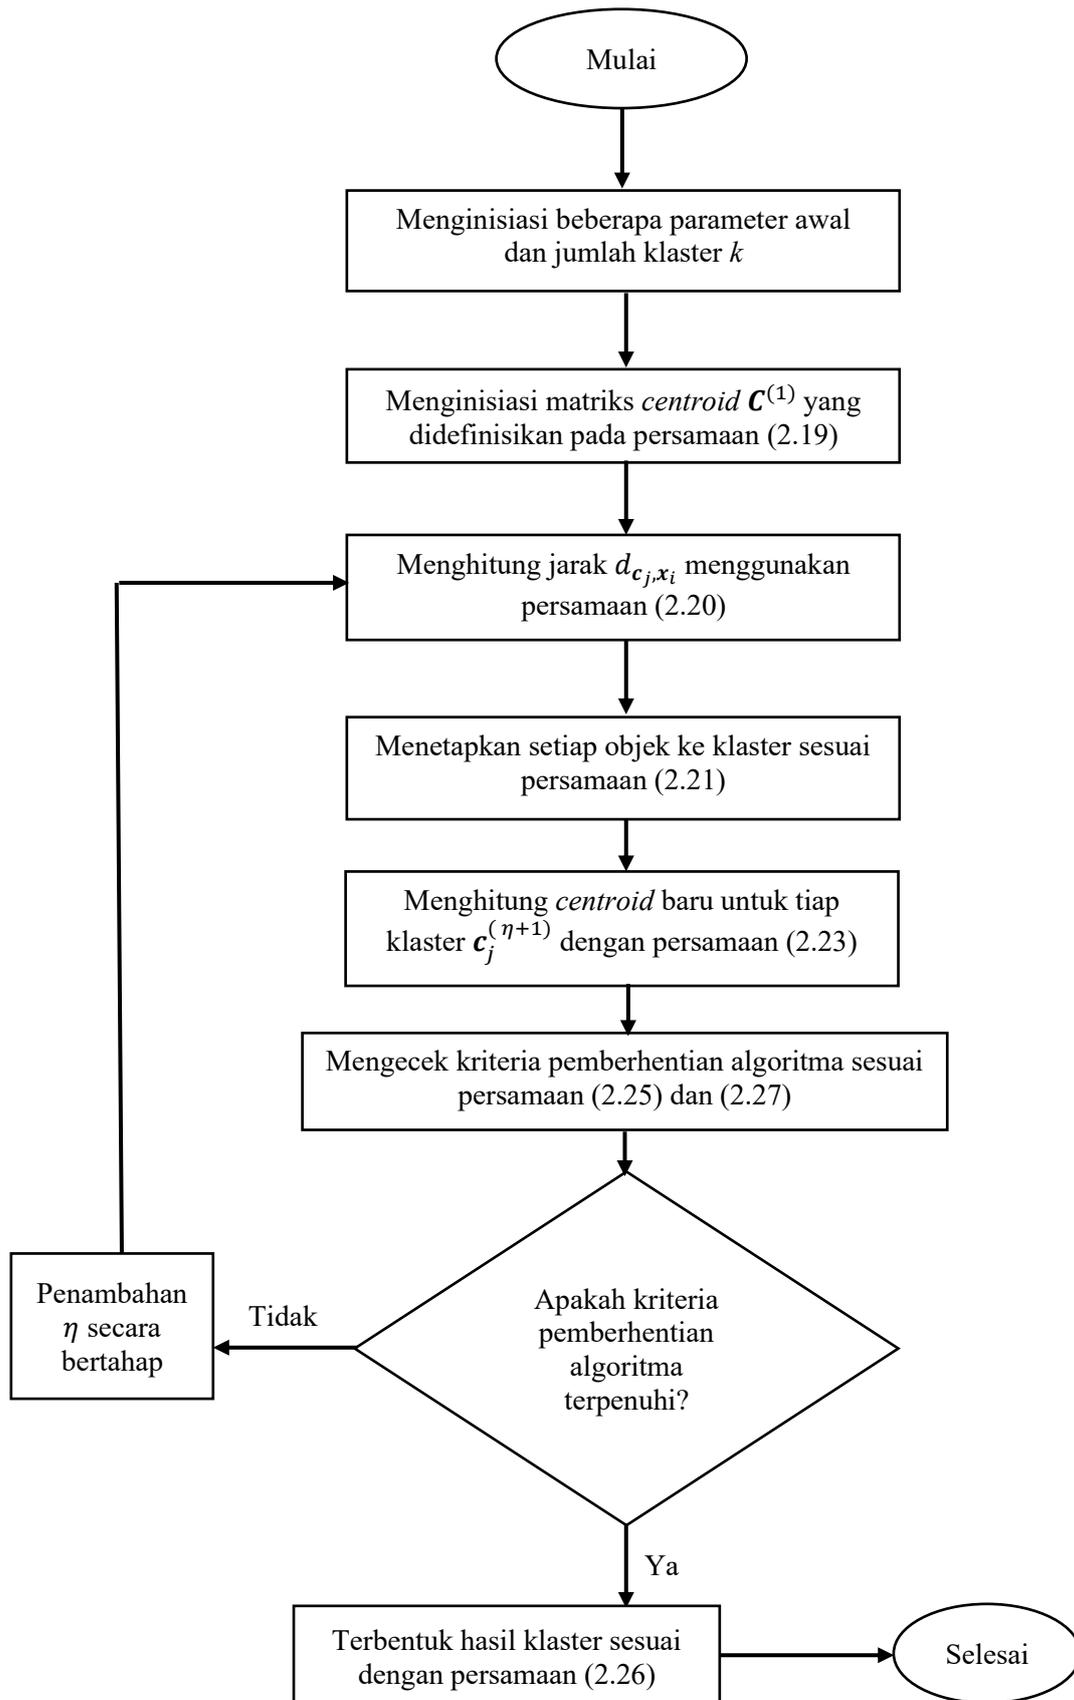
- g. Memperbarui vektor bobot *winning neuron*  $w_g$  sesuai persamaan (2.36). Sedangkan vektor bobot *output neuron* lainnya diperbarui juga sesuai persamaan (2.37).
- h. Mengecek kriteria pemberhentian algoritma, jika  $t < T$ , kembali ke langkah d dan sebaliknya jika  $t > T$ , algoritma sudah selesai.
9. Melakukan evaluasi terhadap kluster yang terbentuk dengan nilai indeks validitas *cluster Silhouette, Davies-Bouldin, dan Calinski-Harabasz*.
10. Memilih hasil *clustering* terbaik di antara algoritma *k-means, fuzzy c-means, dan SOM* berdasarkan nilai indeks validitas *cluster*.
11. Melakukan interpretasi terhadap hasil *clustering* dari algoritma terbaik.
12. Menarik kesimpulan dan merumuskan saran dari hasil penelitian yang diperoleh.

### 3.3. Diagram Alir Penelitian

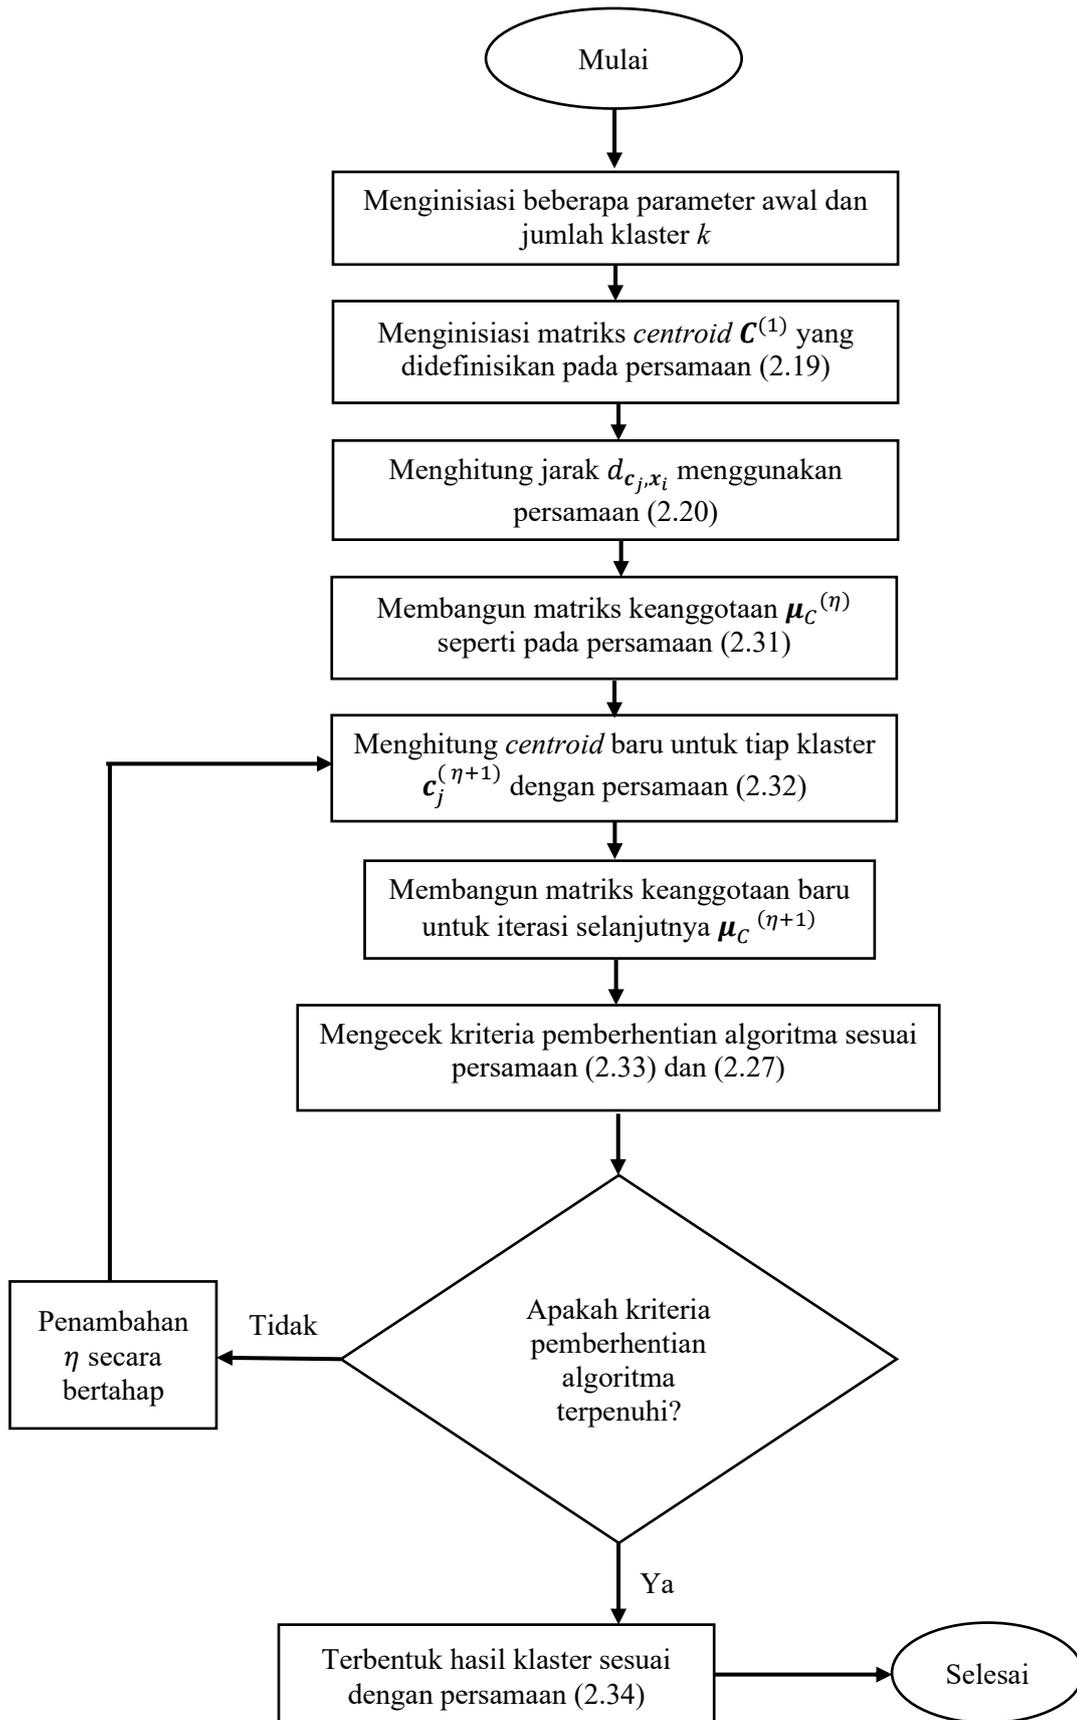
Penelitian ini akan dilaksanakan berdasarkan rancangan penelitian pada Gambar 3.1, Gambar 3.2, Gambar 3.3, dan Gambar 3.4.



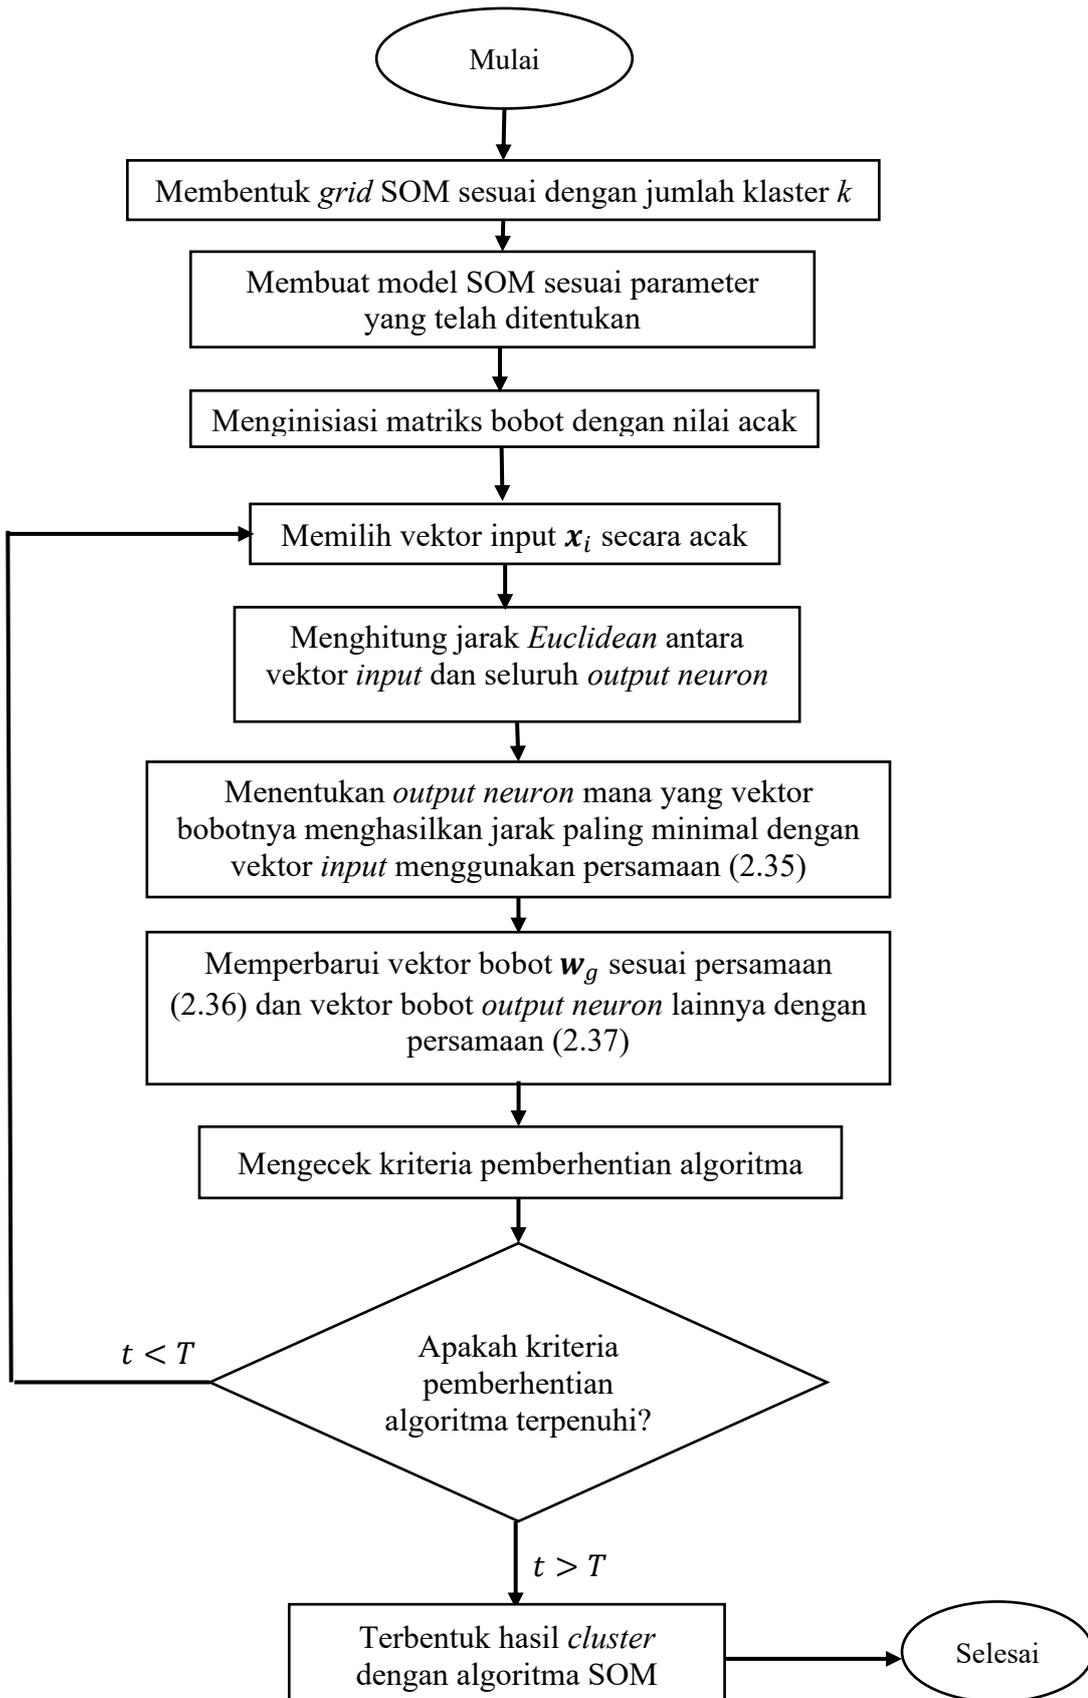
Gambar 3.1 Alur Penelitian



Gambar 3.2 Diagram Alir Algoritma *K-means*



Gambar 3.3 Diagram Alir Algoritma *Fuzzy C-means*



Gambar 3.4 Diagram Alir Algoritma SOM

*“Halaman ini sengaja dikosongkan”*

## BAB IV HASIL DAN PEMBAHASAN

### 4.1. Gambaran Umum Objek Penelitian

Peraturan Otoritas Jasa Keuangan No. 3 Tahun 2022 mengenai penilaian tingkat kesehatan Bank Perkreditan Rakyat (BPR) dan Bank Pembiayaan Rakyat Syariah (BPRS) menjadi landasan hukum bagi BPR dan BPRS dalam menjalankan bisnis dan operasionalnya. Landasan hukum tersebut memacu BPR dan BPRS untuk semakin meningkatkan efektivitas penerapan manajemen risiko dan tata kelola secara maksimal. Sedangkan bagi Otoritas Jasa Keuangan, penilaian tingkat kesehatan dilaksanakan untuk mengetahui kinerja dan kondisi Bank Perkreditan Rakyat dan Bank Pembiayaan Rakyat Syariah guna menetapkan strategi dan fokus pengawasan yang optimal.

Objek penelitian ini ialah Bank Perkreditan Rakyat dan Bank Pembiayaan Rakyat Syariah yang beroperasi di wilayah Surabaya Raya yang meliputi Kabupaten Gresik, Kabupaten Bangkalan, Kabupaten dan Kota Mojokerto, Kota Surabaya, Kabupaten Sidoarjo, serta Kabupaten Lamongan. Bersumber dari laman resmi OJK, Bank Perkreditan Rakyat yang beroperasi di wilayah Surabaya Raya dan memiliki laporan keuangan periode September 2024 berjumlah 84. Nama-nama dari BPR tersebut tertera pada Tabel 4.1.

**Tabel 4.1** Daftar BPR di Surabaya Raya

Nama Kabupaten/Kota	Nama Bank Perkreditan Rakyat
Kabupaten Gresik	PT BPR Balongpanggung Sentosa, PT BPR Dana Rajabally, PT BPR Rajadana Menganti, Perumda BPR Bank Gresik, PT BPR Bank Bumi Sanggabuana, PT BPR Intan Kita, PT BPR Aneka Dana Sejahtera, PT BPR Kebomas, PT BPR Intan Nasional, PT BPR Mitra Cemawis Mandiri, dan PT BPR Lestari Nusantara Indonesia
Kabupaten Bangkalan	Perumda BPR Bangkalan dan PT BPR Dana Kerja Putra
Kabupaten Mojokerto	PT BPR Arta Swasembada, PT BPR Arta Haksaprima, KSP BPR Sendang Harta Sejahtera, PT BPR Bumi Jaya, PT BPR Mojosari Pahalpacto, PT BPR Karunia Berkat Intidana, PT BPR Arta Bangsaal Utama, dan PT BPR Puriseger Sentosa
Kota Mojokerto	PT BPR Majatama Perseroda dan PT BPR Kurnia Dadi Arta
Kota Surabaya	PT BPR Jawa Timur, PT BPR Danamitra Surya, PT BPR Kirana Indonesia, PT BPR Prima Kredit Utama, PT BPR Danamas, PT BPR Guna Yatra, PT BPR Kosanda, PT BPR Bintang Mitra Indonesia, PT BPR Central Niaga, PT BPR Bina Kharisma Insani, PT BPR Surya Arthaguna Abadi, PT BPR Sili Corp Bank, PT BPR Karyaperdana Sejahtera, Permata Artha Surya, PT BPR Surya Artha Utama Perseroda, dan PT BPR Prima Master Bank
Kabupaten Sidoarjo	PT BPR Krian Nusantara, PT BPR Sriekaya, PT BPR Artha Buana, PT BPR Bank Benta Tesa, PT BPR Taman Dhana, PT BPR Arta Waru Surya, PT BPR Satyadhana Artha, PT BPR Buana Dana Makmur, PT BPR Sinardana Buana, PT BPR Bandataman, PT BPR Sarana Sukses, PT BPR Berkat Cahaya Artha, PT BPR Abrin Centra Artha, PT BPR Megakerta Swadiri, PT BPR Dinar Pusaka, PT BPR Bank Ima, PT BPR Gema Nusa, PT BPR Toelangan Dasa Nusantara, PT BPR Sari Dana Indonesia, PT BPR Taman Artha Kencana, PT BPR Padat Ganda,

**Tabel 4.1** Daftar BPR di Surabaya Raya (Lanjutan)

Nama Kabupaten/Kota	Nama Bank Perkreditan Rakyat
	PT BPR Sahabat Mitra Artha, PT BPR Anglomas Indah, PT BPR Dana Raya Jawa Timur, PT BPR Dirgadhana Arthamas, PT BPR Mahkota Krian Wijaya, PT BPR Wutama Artha Sejahtera, PT BPR Sentra Dana Makmur, PT BPR Djojo Mandiri Raya, PT BPR Puridana Arthamas, PT BPR Andalan Daerah, PT BPR Candisaka Arta, PT BPR Mitra Majujaya Mandiri, PT BPR Artamulya Bumimukti, PT BPR Buduran Deltapurnama, PT BPR Bumi Gora Jaya, PT BPR Delta Artha Perseroda, PT BPR Wiradhana Putramas, dan PT BPR Jati Lestari
Kabupaten Lamongan	Perumda BPR Bank Daerah Lamongan, PT BPR Nusamba Brondong, PT BPR Rukun Karya Sari, PT BPR Ulintha Ganda, PT BPR Delta Lamongan, dan PT BPR Mitra Dhanaceswara

Di sisi lain, jumlah Bank Pembiayaan Rakyat Syariah yang beroperasi di wilayah Surabaya Raya dan memiliki laporan keuangan periode September 2024 berjumlah 7 yang dapat dilihat pada Tabel 4.2.

**Tabel 4.2** Daftar BPRS di Surabaya Raya

Nama Kabupaten/Kota	Nama Bank Pembiayaan Rakyat Syariah
Kabupaten Gresik	PT BPRS Amanah Sejahtera dan PT BPRS Mandiri Mitra Sukses
Kota Surabaya	PT BPRS Karya Mugi Sentosa
Kabupaten Sidoarjo	PT BPRS Baktimakmur Indah, PT BPRS Annisa Mukti, dan PT BPRS Unawi Barokah
Kabupaten Lamongan	PT BPRS Madinah

Periode data yang akan diamati pada penelitian ini adalah pada triwulan ketiga atau bulan September tahun 2024. Selain itu, variabel yang akan dianalisis ada sebanyak 6 parameter sehingga dengan 91 objek penelitian akan diperoleh sebanyak 546 data. Data tersebut didapatkan dari laporan keuangan masing-masing BPRS dan BPRS yang kemudian akan dianalisis dengan metode *clustering*. Hasil yang diharapkan adalah masing-masing BPR dan BPRS akan dikelompokkan menjadi beberapa *cluster* berdasarkan variabel kinerja keuangan perbankan.

#### 4.2. Analisis Deskriptif Variabel

Analisis deskriptif bertujuan untuk memberikan deskripsi mengenai data dari setiap variabel-variabel yang akan digunakan. Pada penelitian ini, analisis deskriptif digunakan untuk menemukan gambaran umum yang membentuk penilaian tingkat kesehatan BPR dan BPRS di wilayah Surabaya Raya sebelum melakukan klasterisasi menggunakan metode *k-means*, *fuzzy c-means*, dan *Self-Organizing Maps* (SOM). Deskripsi data akan menggunakan ukuran pemusatan data serta ukuran penyebaran data yang terdiri dari nilai minimum, nilai maksimum, rata-rata, dan standar deviasi. Statistika deskriptif dari 6 variabel kinerja keuangan ditampilkan dalam Tabel 4.3.

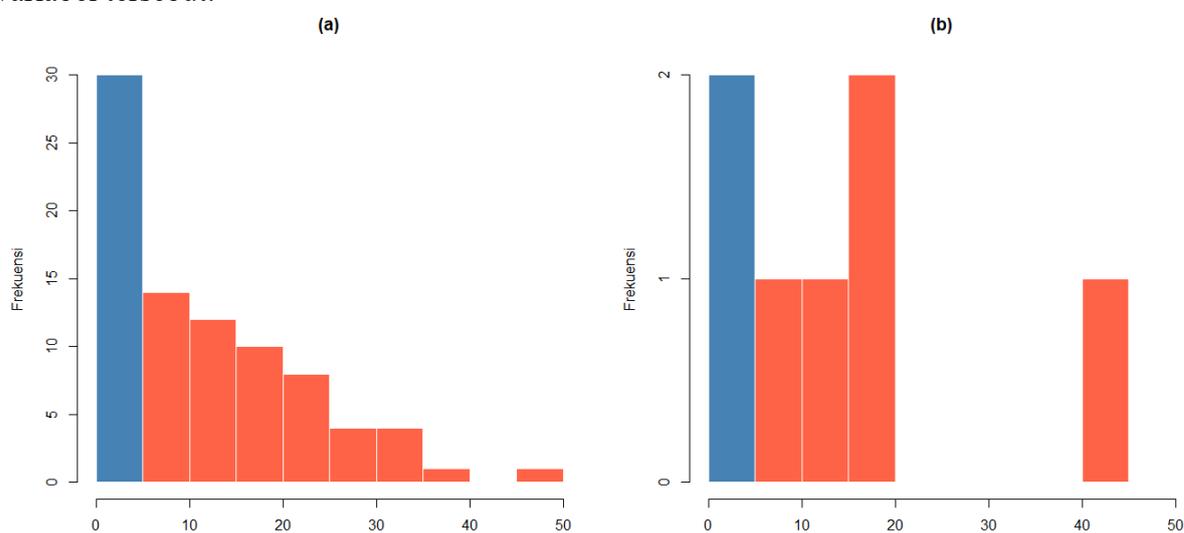
**Tabel 4.3** Statistika Deskriptif Data

Variabel	Bank	<i>n</i>	Nilai Minimum	Nilai Maksimum	Rata-rata	Standar Deviasi
NPL	BPR	84	0,00	47,25	11,7864	10,2777
	BPRS	7	4,19	44,06	15,1329	13,7636
LDR	BPR	84	0,00	4312,90	240,6418	577,1074
	BPRS	7	88,99	316,67	140,8329	79,1398

**Tabel 4.3** Statistika Deskriptif Data (Lanjutan)

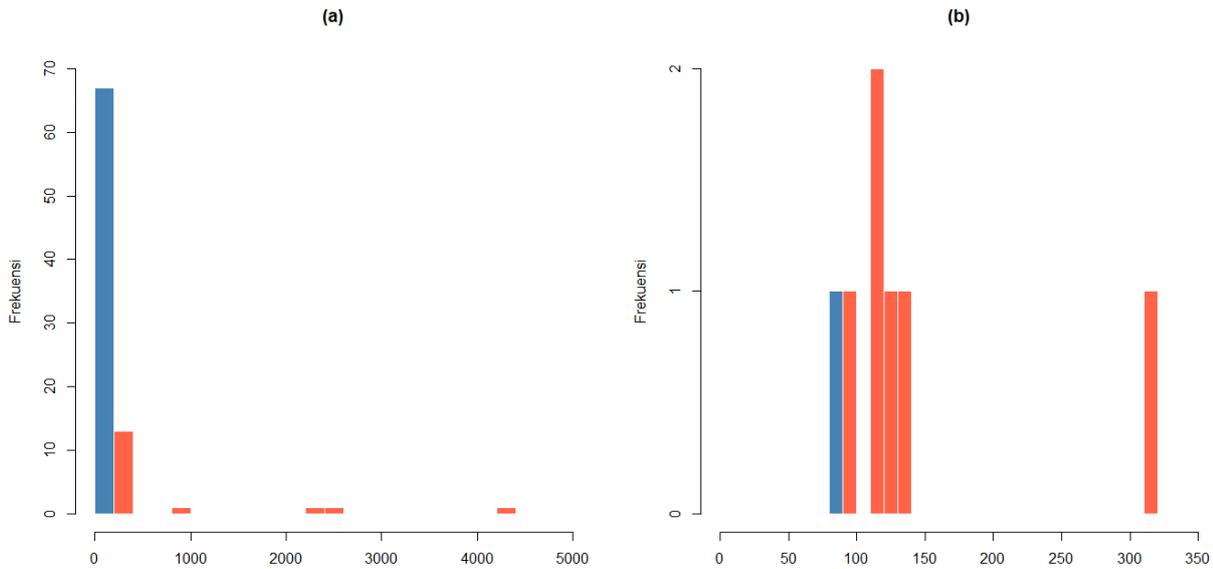
Variabel	Bank	n	Nilai Minimum	Nilai Maksimum	Rata-rata	Standar Deviasi
BOPO	BPR	84	0,00	198,31	94,4378	28,3278
	BPRS	7	82,32	154,29	103,0285	25,2339
ROA	BPR	84	-12,12	16,31	1,3138	4,2398
	BPRS	7	-4,93	2,47	-0,0886	2,7092
NIM/NI	BPR	84	-0,26	46,78	12,2995	7,4030
	BPRS	7	3,10	14,05	9,3257	3,5673
KPMM	BPR	84	0,00	485,63	91,8528	84,5590
	BPRS	7	15,78	63,08	39,4586	18,3257

Dari Tabel 4.3 diperoleh informasi bahwa variabel ROA baik BPR dan BPRS memiliki nilai minimum paling kecil yakni masing-masing sebesar -12,12% dan -4,93%. Sedangkan variabel dengan nilai maksimum terbesar adalah rasio LDR yang sebesar 4312,90% untuk BPR dan 316,67% untuk BPRS. Berdasarkan nilai rata-rata dan standar deviasi, keenam variabel memiliki nilai rata-rata dan standar deviasi yang beragam. Variabel LDR dan ROA pada BPR memiliki nilai standar deviasi lebih besar dibandingkan nilai rata-ratanya. Hal tersebut menunjukkan adanya simpangan data pada kedua variabel tersebut. Sebaliknya variabel NPL, BOPO, NIM, dan KPMM milik BPR mempunyai, nilai standar deviasi yang lebih kecil dari nilai rata-ratanya yang menunjukkan bahwa simpangan data cenderung kecil pada keempat variabel tersebut. Hampir serupa dengan BPR, variabel ROA pada BPRS juga memiliki nilai standar deviasi lebih besar dibandingkan nilai rata-ratanya. Hal tersebut menunjukkan terdapat simpangan data pada variabel tersebut. Sebaliknya pada variabel sisanya yakni NPL, LDR, BOPO, NI, dan KPMM dari BPRS, nilai standar deviasi pada keempat variabel tersebut lebih kecil dari nilai rata-ratanya yang menunjukkan bahwa simpangan data cenderung kecil pada variabel tersebut.



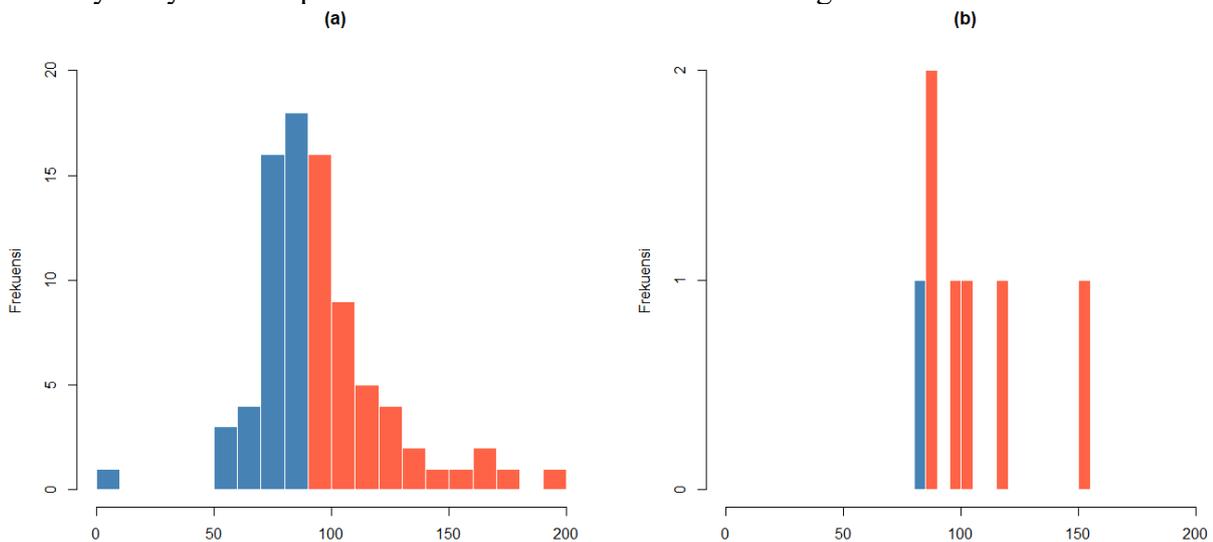
**Gambar 4.1** Histogram Rasio NPL BPR (a) dan BPRS (b)

Rasio *Non Performing Loan* yang digunakan untuk mendeskripsikan kemampuan bank dalam menghindari terjadinya kredit atau pembiayaan macet termasuk dalam indikator penilaian kesehatan BPR dan BPRS pada faktor profil risiko. Dari Gambar 4.1 terlihat bahwa sebanyak 30 BPR dan 2 BPRS di wilayah Surabaya Raya memiliki rasio NPL kurang dari 5%. Angka tersebut mencerminkan sebagian besar BPR dan BPRS di wilayah Surabaya Raya masih belum cukup mampu menghindari terjadinya kredit atau pembiayaan macet. Hal itu tercermin dari rasio NPL yang sebagian besar masih melebihi batas minimum yang ditetapkan oleh Otoritas Jasa Keuangan.



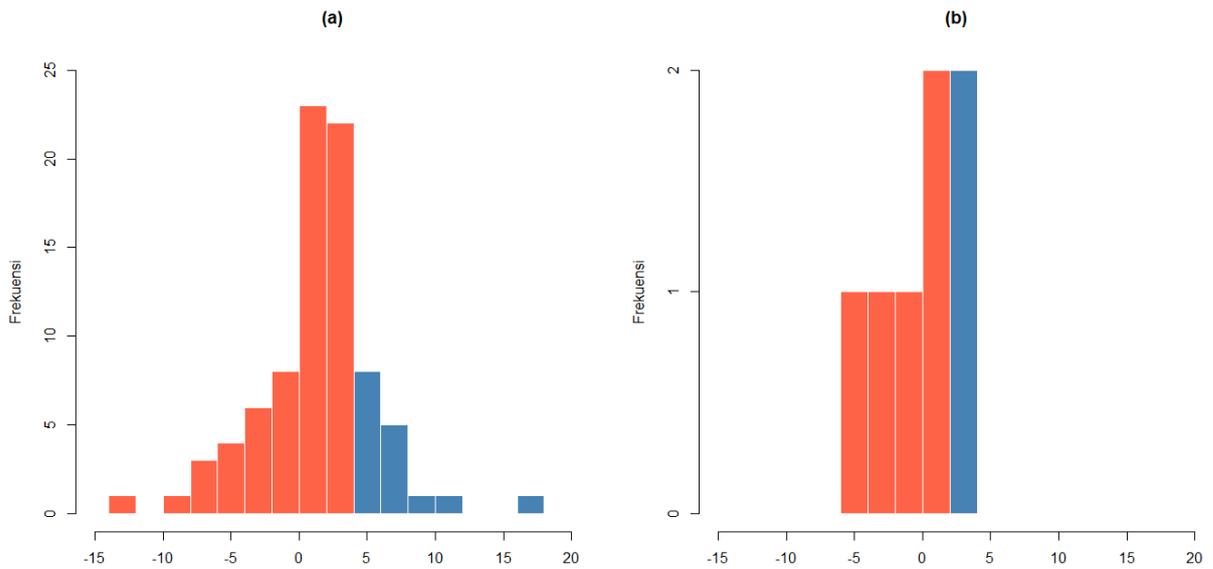
**Gambar 4.2** Histogram Rasio LDR BPR (a) dan BPRS (b)

Variabel selanjutnya yang juga merupakan variabel indikator penilaian kesehatan BPR dan BPRS pada faktor profil risiko adalah variabel *Loan to Deposit Ratio* (LDR). Rasio ini mengukur komposisi jumlah kredit terhadap dana dan modal yang digunakan. Terlihat pada Gambar 4.2, hampir seluruh BPR di wilayah Surabaya Raya memiliki nilai rasio LDR dibawah batas maksimum yang ditetapkan oleh OJK. Sebaliknya, dari 7 BPRS, hanya 1 BPRS yang memiliki rasio LDR kurang dari 90%. Perbedaan tersebut menunjukkan bahwa di wilayah Surabaya Raya kemampuan likuiditas BPR lebih baik dibandingkan BPRS.



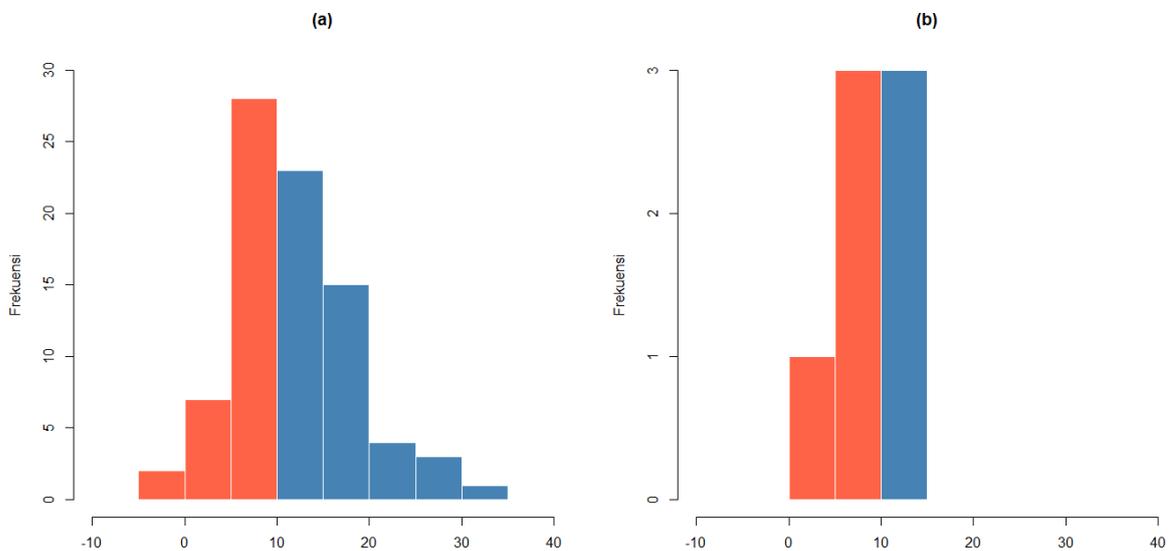
**Gambar 4.3** Histogram Rasio BOPO BPR (a) dan BPRS (b)

Rasio Biaya Operasional terhadap Pendapatan Operasional atau lebih sering disingkat BOPO merupakan ukuran yang digunakan dalam penilaian tingkat kesehatan BPR dan BPRS pada faktor tata kelola. Rasio BOPO pada BPR dan BPRS di wilayah Surabaya Raya digambarkan oleh Gambar 4.3 yang mana terlihat bahwa 35 BPR dan 1 BPRS dikatakan telah efisien dalam penerapan manajemen dan tata kelola yang baik. Jumlah tersebut menunjukkan kualitas manajemen sebagian besar BPR dan BPRS di wilayah Surabaya Raya atas penerapan prinsip tata kelola yang baik masih rendah. Hal itu dikarenakan masih banyak BPR dan BPRS yang memiliki rasio BOPO bernilai lebih dari 85% yang merupakan batas maksimum yang ditetapkan oleh OJK.



**Gambar 4.4** Histogram Rasio ROA BPR (a) dan BPRS (b)

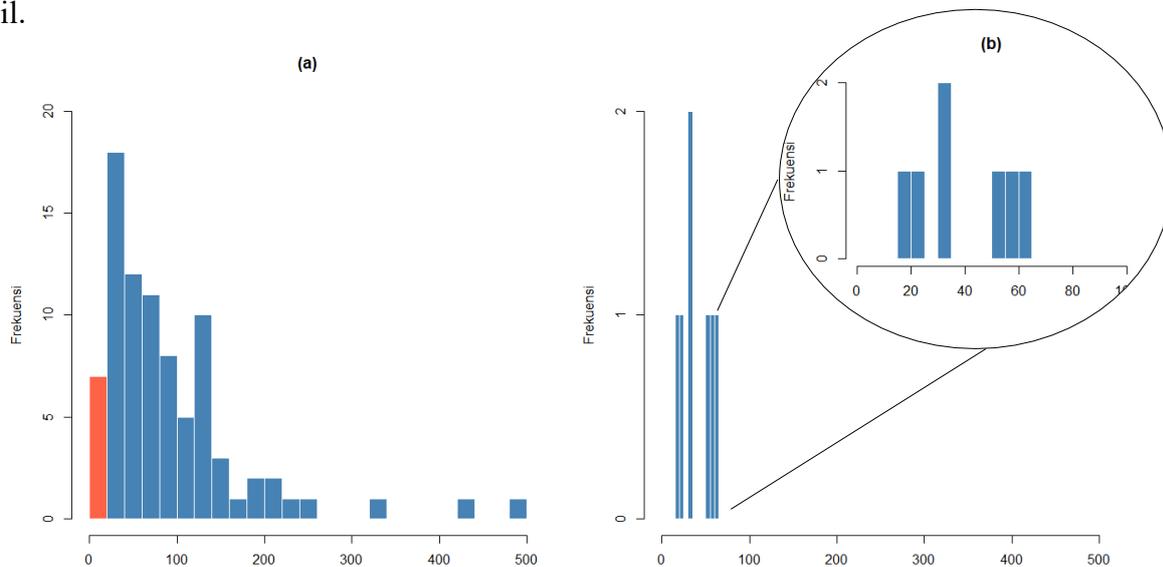
*Return on Asset* (ROA) termasuk dalam rasio yang mendasari penilaian tingkat kesehatan BPR dan BPRS pada faktor rentabilitas. Dapat diketahui dari Gambar 4.4 bahwa hanya 37 BPR dan 2 BPRS di wilayah Surabaya Raya yang memiliki rasio ROA bernilai lebih dari 2%. Angka tersebut adalah batasan minimum yang ditetapkan OJK untuk kategori rentabilitas bank yang baik. Hasil yang diperlihatkan oleh Gambar 4.4 menunjukkan bahwa sebagian besar BPR dan BPRS di wilayah Surabaya Raya masih memiliki kemampuan yang rendah dalam memperoleh laba untuk mendukung permodalan dan kegiatan operasional secara memadai.



**Gambar 4.5** Histogram Rasio NIM BPR (a) dan NI BPRS (b)

Variabel kedua dalam penilaian tingkat kesehatan BPR dan BPRS pada faktor rentabilitas adalah rasio *Net Interest Margin* (NIM) untuk BPR dan *Net Imbalan* (NI) untuk BPRS. NIM merupakan rasio yang mengukur kemampuan BPR dalam memperoleh keuntungan bersih terkait dengan pendapatan bunga bersih, sedangkan NI digunakan untuk mengukur kemampuan BPRS dalam menghasilkan pendapatan dari penyaluran dana bersih. Dari Gambar 4.5 di atas terlihat bahwa terdapat 45 BPR yang memiliki rasio NIM lebih dari 10%. Angka tersebut menunjukkan bahwa lebih dari separuh BPR di wilayah Surabaya Raya memiliki kemampuan yang baik dalam memperoleh keuntungan terkait pendapatan bunga. Di sisi lain, hanya 3 BPRS yang memiliki rasio NI lebih dari 10%. Hal tersebut menunjukkan bahwa kemampuan

memperoleh keuntungan atas penyaluran dana bersih pada hampir separuh BPRS di wilayah Surabaya Raya dikatakan baik sehingga kemungkinan bank dalam kondisi bermasalah semakin kecil.



**Gambar 4.6** Histogram Rasio KPMM BPR (a) dan BPRS (b)

Variabel terakhir dalam penelitian ini yang termasuk dalam penilaian tingkat kesehatan BPR dan BPRS pada faktor permodalan adalah rasio Kewajiban Pemenuhan Modal Minimum (KPMM). Penilaian pada faktor permodalan menilai kecukupan modal BPR dan BPRS untuk menyerap potensi kerugian pada saat ini dan di waktu mendatang. Berdasarkan Gambar 4.6, didapatkan informasi bahwa hanya 6 BPR yang memiliki rasio KPMM bernilai kurang dari 15%. Angka tersebut menunjukkan hampir semua BPR dan seluruh BPRS di wilayah Surabaya Raya termasuk dalam kategori baik dari segi kondisi permodalan. Artinya, modal yang dimiliki BPR dan BPRS tersebut mampu mendukung pelaksanaan aktivitas bank dengan meminimalkan jumlah aktiva mengandung risiko yang ikut dibiayai modal bank.

### 4.3. Hasil Identifikasi Multikolinearitas

Sebelum melakukan analisis *clustering*, perlu dilakukan pengujian asumsi yakni identifikasi multikolinearitas. Identifikasi tersebut bertujuan untuk mengetahui apakah terdapat hubungan linear antara variabel dalam penelitian. Statistik uji dalam mengidentifikasi adanya multikolinearitas adalah dengan menghitung nilai *Variance Inflation Factor* (VIF). Nilai VIF lebih dari 10 disimpulkan sebagai indikasi bahwa data memiliki masalah kolinearitas (Chatterjee dan Hadi, 2012, p. 249-250). Apabila terdapat hubungan linear antar variabel, maka variabel tersebut akan dieliminasi dan tidak digunakan dalam penelitian.

Sebagai contoh, untuk menghitung nilai VIF variabel NPL pada BPR, NPL sebagai variabel prediktor akan diregresikan dengan LDR, BOPO, ROA, NIM, dan KPMM sebagai variabel respon. Setelah didapatkan nilai koefisien regresinya, nilai koefisien determinasi dihitung menggunakan persamaan (2.13) sebagai berikut,

$$R^2 = \frac{(-0,002)((14,60 \times 371,26) + \dots + (6,81 \times 141,38)) + \dots + (-0,013)((14,60 \times 120,89) + \dots + (6,81 \times 115,04))}{14,60^2 + 4,80^2 + \dots + 6,81^2}$$

$$R^2 = \frac{ESS}{TSS} = \frac{674,925}{8768,380} = 0,07$$

Setelah diperoleh nilai koefisien determinasi variabel NPL ( $p$ ), Nilai VIF dihitung menggunakan persamaan (2.12).

$$VIF_p = \frac{1}{(1 - 0,07)} = 1,0834$$

Perhitungan nilai VIF masing-masing variabel pada BPR dan BPRS secara lengkap disajikan pada Tabel 4.4.

**Tabel 4.4** Nilai VIF Variabel BPR dan BPRS

Perbankan	Variabel					
	NPL	LDR	BOPO	ROA	NIM/NI	KPMM
BPR	1,0834	1,1037	3,0237	3,9579	1,6538	1,1430
BPRS	261,4038	15,0512	626,0332	100,5374	6,8769	18,9201

Berdasarkan Tabel 4.4, nilai VIF semua variabel dari rasio-rasio pada BPR bernilai kurang dari 10 sehingga dapat disimpulkan bahwa tidak terdapat indikasi multikolinearitas antar variabel-variabel tersebut. Akan tetapi bagi rasio-rasio pada BPRS, nilai VIF pada variabel NPL, LDR, BOPO, ROA, dan KPMM bernilai lebih dari 10 sebagaimana terlampir pada Tabel 4.4. Oleh karenanya, dapat diketahui adanya indikasi multikolinearitas pada variabel-variabel pada BPRS. Karena asumsi belum terpenuhi, perlu dilakukan pengeliminasian variabel satu per satu hingga seluruh nilai VIF bernilai kurang dari 10. Pengeliminasian variabel pada BPRS dimulai dari variabel BOPO sebab nilai VIF-nya paling besar. Setelah variabel BOPO dihapuskan, eliminasi berikutnya dilakukan terhadap variabel ROA. Hasil perhitungan nilai VIF variabel-variabel BPRS setelah penghapusan variabel BOPO dan juga ROA disajikan pada Tabel 4.5.

**Tabel 4.5** Nilai VIF Variabel BPRS yang Telah Memenuhi Asumsi

Perbankan	Variabel			
	NPL	LDR	NI	KPMM
BPRS	1,1400	1,4167	1,8524	2,4033

Berdasarkan Tabel 4.5, nilai VIF empat variabel BPRS pasca pengeliminasian dua variabel telah bernilai kurang dari 10 sehingga dapat disimpulkan bahwa tidak terdapat indikasi multikolinearitas di antara empat variabel tersebut. Dengan demikian, variabel yang akan digunakan dalam analisis *clustering* bagi BPR adalah NPL, LDR, BOPO, ROA, NIM, dan KPMM. Akan tetapi, bagi BPRS, analisis *clustering* akan dilakukan berdasarkan 4 variabel yang telah memenuhi asumsi multikolinearitas yakni NPL, LDR, NI, dan KPMM.

#### 4.4. Standarisasi Data

Berdasarkan Tabel 4.3 dapat dilihat bahwa variabel-variabel dalam penelitian ini memiliki rentang yang bervariasi. Misalnya rasio LDR memiliki rentang yang lebih besar dibandingkan rasio ROA. Oleh karenanya diperlukan *preprocessing data* dengan menstandarisasi data. Standarisasi dilakukan untuk membantu mengurangi pengaruh yang terlalu mendominasi dari variabel-variabel yang memiliki rentang lebih lebar. *Preprocessing data* akan dilakukan menggunakan *z-score standardization*. *Z-score standardization* dipilih karena dapat beradaptasi pada rentang nilai yang bervariasi sehingga lebih stabil pada data yang mengandung *outlier* (Kamber dan Han, 2006). Data yang digunakan pada penelitian tercantum pada Tabel 4.6 dan Tabel 4.7. Data penelitian secara lengkap dilampirkan pada Lampiran 1.

**Tabel 4.6** Data 6 Variabel BPR

<i>n</i>	NPL	LDR	BOPO	ROA	NIM	KPMM
1	14,60	371,26	66,53	9,08	23,07	120,89
2	4,80	2455,05	71,21	5,24	16,32	254,13
⋮	⋮	⋮	⋮	⋮	⋮	⋮
83	8,92	124,50	85,38	3,17	18,02	94,44
84	6,81	141,38	70,54	6,46	15,58	115,04

**Tabel 4.7** Data 4 Variabel BPRS

<b>n</b>	<b>NPL</b>	<b>LDR</b>	<b>NI</b>	<b>KPMM</b>
1	10,50	88,99	9,14	23,33
2	16,62	110,12	8,71	15,78
⋮	⋮	⋮	⋮	⋮
6	8,83	316,67	10,34	54,46
7	17,20	120,73	12,52	56,38

Seluruh observasi pada Tabel 4.6 dan 4.7 akan dilakukan *preprocessing* dengan *z-score standardization*. Sebagai contoh variabel NPL pada data ke-1 BPRS ( $x_{1_1}$ ) di Tabel 4.7 distandarisasi dengan langkah-langkah sebagai berikut,

1. Menghitung rata-rata seluruh data pada variabel NPL ( $\bar{x}_1$ ) dengan persamaan (2.9)

$$\bar{x}_1 = \frac{(10,50 + 16,62 + \dots + 17,20)}{7} = 15,13$$

2. Menghitung standar deviasi seluruh data pada variabel NPL ( $sd_1$ ) dengan persamaan (2.10)

$$sd_1 = \sqrt{\frac{\sum_{i=1}^7 (x_{i_1} - \bar{x}_1)^2}{7 - 1}}$$

$$sd_1 = \sqrt{\frac{(10,50 - 15,13)^2 + (16,62 - 15,13)^2 + \dots + (17,20 - 15,13)^2}{6}}$$

$$sd_1 = \sqrt{\frac{21,44 + 2,22 + \dots + 4,28}{6}} = 13,76$$

3. Menghitung nilai standarisasi *z-score* untuk variabel  $x_{1_1}$  sesuai persamaan (2.8)

$$x_{1_1}^* = \frac{x_{1_1} - \bar{x}_1}{sd_1} = \frac{10,50 - 15,13}{13,76} = -0,3366$$

Hasil standarisasi *z-score* dari data pada Tabel 4.6 dan Tabel 4.7 masing-masing disajikan pada Tabel 4.8 dan Tabel 4.9. Secara lengkap, data penelitian yang telah distandarisasi dilampirkan pada Lampiran 2.

**Tabel 4.8** Data Standarisasi 6 Variabel BPR

<b>n</b>	<b>NPL</b>	<b>LDR</b>	<b>BOPO</b>	<b>ROA</b>	<b>NIM</b>	<b>KPMM</b>
1	0,2737	0,2263	-0,9864	1,8317	1,4549	0,3434
2	-0,6798	3,8371	-0,8212	0,9260	0,5430	1,9191
⋮	⋮	⋮	⋮	⋮	⋮	⋮
83	-0,2789	-0,2013	-0,3210	0,4378	0,7727	0,0306
84	-0,4842	-0,1720	-0,8449	1,2138	0,4431	0,2742

**Tabel 4.9** Data Standarisasi 4 Variabel BPRS

<b>n</b>	<b>NPL</b>	<b>LDR</b>	<b>NI</b>	<b>KPMM</b>
1	-0,3366	-0,6551	-0,0521	-0,8801
2	0,1080	-0,3881	-0,1726	-1,2921
⋮	⋮	⋮	⋮	⋮
6	-0,4579	2,2218	0,2843	0,8186
7	0,1502	-0,2540	0,8954	0,9234

Selanjutnya, dalam seluruh analisis *clustering* dengan ketiga algoritma, akan dicobakan dengan menggunakan data asli sebagaimana pada Tabel 4.6 dan Tabel 4.7 serta data yang telah dilakukan standarisasi sebagaimana pada Tabel 4.8 dan Tabel 4.9. Hal tersebut dilakukan untuk mengetahui sejauh mana standarisasi mempengaruhi hasil akhir klasterisasi.

#### 4.5. Klasterisasi Menggunakan Algoritma *K-means*

Seperti yang sudah dijelaskan pada bagian sebelumnya, digunakan data tanpa standarisasi dan data yang telah distandarisasi untuk melakukan analisis *clustering*. Kemudian dalam melakukan analisis *clustering* dengan algoritma *k-means*, harus ditentukan terlebih dahulu jumlah klaster yang mewakili banyaknya kelompok yang akan terbentuk. Setelah melakukan analisis *clustering* sesuai dengan jumlah klaster yang ditentukan, setiap hasil klasterisasi akan dievaluasi menggunakan nilai indeks validitas *cluster Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz*. Terakhir, dilakukan pemilihan hasil klasterisasi terbaik untuk tiap jenis perbankan berdasarkan ketiga nilai indeks validitas *cluster*.

##### 4.5.1. BPR

Berdasarkan jumlah klaster yang dihasilkan pada penelitian oleh Puspita dan Pratiwi (2016), Pristiyandini (2018), dan juga Guna (2023) serta jumlah peringkat pada Peraturan OJK No.3 Tahun 2022 tentang Penilaian Tingkat Kesehatan BPR dan BPRS, jumlah klaster yang digunakan untuk pengelompokan BPR adalah 3, 4, dan 5. Selanjutnya, analisis *clustering* dengan algoritma *k-means* dilakukan dengan tahapan sebagai berikut,

- Menginisiasi indeks iterasi awal  $\eta = 1$  dan jumlah iterasi maksimum  $\eta_{max} = 100$  (Borlea dkk., 2021; Yohannes, 2016).
- Menginisiasi matriks *centroid* awal secara acak sesuai persamaan (2.19). Ukuran matriks *centroid* disesuaikan dengan jumlah variabel yang dimiliki dan jumlah klaster yang ingin dibentuk. Sebagai contoh dalam pengelompokan BPR menjadi 3 klaster, matriks *centroid* memiliki ukuran  $[6 \times 3]$  seperti berikut,

$$C^{(1)} = \begin{bmatrix} 4,80 & 0,00 & 0,00 \\ 2455,05 & 0,00 & 4312,90 \\ 71,21 & 0,00 & 95,91 \\ 5,24 & -2,53 & 0,82 \\ 16,32 & 0,00 & 4,32 \\ 254,13 & 0,00 & 212,25 \end{bmatrix}$$

- Menghitung jarak  $d_{c_j, x_i}$  untuk tiap kombinasi objek  $x_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan (2.20)

Sebagai contoh untuk data BPR ke-1 yakni,

$$x_1 = [14,60 \quad 371,26 \quad 66,53 \quad 9,08 \quad 23,07 \quad 120,89]$$

Jarak  $c_1$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$d_{c_1, x_1} = \sqrt{(14,60 - 4,80)^2 + (371,26 - 2455,05)^2 + (66,53 - 71,21)^2 + \sqrt{(9,08 - 5,24)^2 + (23,07 - 16,32)^2 + (120,89 - 254,13)^2} = 2088,09$$

Jarak  $c_2$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$d_{c_2, x_1} = \sqrt{(14,60 - 0,00)^2 + (371,26 - 0,00)^2 + (66,53 - 0,00)^2 + \sqrt{(9,08 - (-2,53))^2 + (23,07 - 0,00)^2 + (120,89 - 0,00)^2} = 397,18$$

Jarak  $c_3$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$d_{c_3, x_1} = \sqrt{(14,60 - 0,00)^2 + (371,26 - 4312,90)^2 + (66,53 - 95,91)^2 + \sqrt{(9,08 - 0,82)^2 + (23,07 - 4,32)^2 + (120,89 - 212,25)^2} = 3942,89$$

Setelah menghitung seluruh jarak  $d_{c_j, x_i}$  untuk tiap kombinasi objek dan *centroid*, diperoleh matriks jarak berukuran  $[84 \times 3]$  sebagai berikut

$$D^{(1)} = \begin{bmatrix} 2088,99 & 397,18 & 3942,89 \\ 0,00 & 2469,27 & 1858,54 \\ \vdots & \vdots & \vdots \\ 2336,06 & 179,29 & 4190,10 \\ 2317,85 & 196,39 & 4172,75 \end{bmatrix}$$

d. Menetapkan semua objek data ke salah satu  $k$  kluster berdasarkan jarak  $d_{c_j, x_i}$  terdekat sebagaimana persamaan (2.21).

Sebagai contoh untuk data BPR ke-1 ( $x_1$ ), jarak  $d_{c_j, x_1}$  terdekat adalah 397,18. Sehingga  $x_1$  dikelompokkan ke dalam kluster 2.

e. Menghitung *centroid* baru untuk setiap kluster yakni  $c_j^{(\eta+1)}$  berdasarkan nilai rata-rata dari semua objek data yang termasuk dalam sebuah kluster dengan persamaan (2.23).

Sebagai contoh, kluster 2 yang terdiri atas 81 objek data, *centroid* baru untuk variabel NPL dihitung dengan rumus sebagai berikut

$$c_{2_1}^{(2)} = \frac{1}{81} \sum_{x_i \in c_2^{(\eta)}} x_{i_1} = \frac{1}{81} (14,60 + \dots + 8,92 + 6,81) = 38,77$$

Setelah perhitungan seluruh *centroid* baru untuk tiap variabel dan tiap kluster, diperoleh matriks *centroid* baru sebagai berikut,

$$C^{(2)} = \begin{bmatrix} 2,91 & 38,77 & 0,00 \\ 2366,51 & 645,84 & 4312,90 \\ 80,69 & 257,45 & 95,91 \\ 3,78 & 11,38 & 0,82 \\ 19,30 & 47,02 & 4,32 \\ 211,30 & 295,79 & 212,25 \end{bmatrix}$$

f. Mengecek kriteria pemberhentian algoritma yakni persamaan (2.25) dan kemudian (2.27). Jika memenuhi, hasil kluster sesuai dengan persamaan (2.26). Jika tidak,  $\eta$  ditambah secara bertahap dan tahapan diulang dari langkah ke-c.

Berdasarkan kriteria pemberhentian persamaan (2.25),  $C^{(2)} = C^{(1)}$  tidak terpenuhi atau matriks *centroid* masih berubah setelah dua iterasi berturut-turut. Oleh karena itu, tahapan *clustering* diulang kembali dari langkah ke-c sampai menemukan hasil klusterisasi yang optimal dan memenuhi kriteria pemberhentian algoritma.

Setelah mendapatkan hasil klusterisasi untuk setiap jumlah kluster, hasil klusterisasi dievaluasi menggunakan nilai validitas *cluster* indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz*.

## 1. Indeks *Silhouette*

Evaluasi hasil pengelompokan BPR dengan indeks *Silhouette* diperoleh dengan mendapatkan nilai indeks *Silhouette* per objek data terlebih dahulu. Kemudian nilai indeks *Silhouette* seluruh objek dalam *dataset* dihitung rata-ratanya agar didapatkan nilai indeks

*Silhouette* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Silhouette* hasil klusterisasi algoritma *k-means* 3 klaster dari data BPR tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Untuk data BPR ke-1 ( $x_1$ ) yang dikelompokkan ke klaster 2 beranggotakan 81, dihitung rerata ketidaksamaan ( $a_1$ ) yakni rata-rata jarak  $x_1$  terhadap  $x_i$  lain pada klaster 2.

$$a_1 = \frac{\sum_{j=1}^{n_2} \|x_1 - x_j\|}{n_2 - 1}, j \neq 1$$

$$= \frac{\|x_1 - x_2\| + \dots + \|x_1 - x_{81}\|}{81 - 1} = \frac{273,29 + \dots + 230,26}{80} = 267,13$$

- b. Selanjutnya, menghitung rerata ketidaksamaan  $d(1, C)$  antara  $x_1$  pada klaster 2 terhadap semua  $x_i$  di klaster C yang mana C adalah semua klaster selain klaster 2. Nilai  $d(1, C_1)$  dimana klaster 1 terdiri atas 2 anggota adalah,

$$d(1, C_1) = \frac{\sum_{j=1}^{n_1} \|x_{1C_2} - x_{jC_1}\|}{n_1}$$

$$= \frac{\|x_{1C_2} - x_{1C_1}\| + \|x_{1C_2} - x_{2C_1}\|}{2} = \frac{2088,09 + 1907,51}{2} = 1997,80$$

Sedangkan nilai  $d(1, C_3)$  dimana klaster 3 terdiri dari 1 anggota adalah,

$$d(1, C_3) = \frac{\|x_{1C_2} - x_{1C_3}\|}{1} = 3942,89$$

- c. Setelah menghitung  $d(1, C)$  untuk semua klaster selain klaster 2, dipilih nilai minimum dari  $d(1, C)$  yang akan disebut sebagai  $b_1$ .

$$b_1 = \min(d(1, C_1); d(1, C_3)) = \min(1997,80 ; 3942,89) = 1997,80$$

- d. Kemudian nilai indeks *Silhouette* untuk data BPR ke-1 ( $x_1$ ) dihitung dengan persamaan (2.39) sebagai berikut,

$$Sil_1 = \frac{(b_1 - a_1)}{\max(a_1, b_1)} = \frac{(1997,80 - 267,13)}{\max(1997,80 ; 267,13)} = 0,8663$$

- e. Terakhir nilai indeks *Silhouette* hasil klusterisasi algoritma *k-means* 3 klaster diperoleh dengan menghitung rata-rata  $Sil_i$  semua objek data.

$$Sil = \frac{1}{n} \sum_{i=1}^n Sil_i = \frac{1}{84} (0,8863 + \dots + 0,9459) = 0,9157$$

## 2. Indeks *Davies-Bouldin*

Evaluasi hasil pengelompokan BPR dengan indeks *Davies-Bouldin* diperoleh dengan mendapatkan perhitungan rata-rata jarak setiap objek data terhadap pusat klaster dan jarak antar pusat klaster terlebih dahulu. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Davies-Bouldin* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Davies-Bouldin* hasil klusterisasi algoritma *k-means* 3 klaster dari data BPR tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung nilai rata-rata jarak tiap objek data terhadap pusat klasternya ( $S_i$ ) untuk setiap klaster dengan persamaan (2.42)

$$S_1 = \frac{1}{n_1} \sum_{j=1}^{n_1} \|x_j - c_1\| = \frac{1}{2} (98,88 + 98,88) = 98,88$$

$$S_2 = \frac{1}{n_2} \sum_{j=1}^{n_2} \|x_j - c_2\| = \frac{1}{81} (237,85 + 36,59 + \dots + 37,83) = 203,81$$

$$S_3 = \frac{1}{n_3} \sum_{j=1}^{n_3} \|x_j - c_3\| = \frac{1}{1} (0,00) = 0,00$$

- b. Menghitung jarak separasi antar kluster ( $M_{ij}$ ) untuk setiap pasangan *centroid* saat  $i \neq j$  sesuai persamaan (2.43)

$$M_{1,2} = \|c_1 - c_2\| = \sqrt{(2,91 - 12,15)^2 + \dots + (211,30 - 87,41)^2} = 2232,15$$

$$M_{1,3} = \|c_1 - c_3\| = \sqrt{(2,91 - 0,00)^2 + \dots + (211,30 - 212,25)^2} = 1946,51$$

$$M_{2,3} = \|c_2 - c_3\| = \sqrt{(12,15 - 0,00)^2 + \dots + (87,41 - 212,25)^2} = 4176,91$$

- c. Menghitung nilai  $R_{ij}$  untuk setiap pasangan *centroid* saat  $i \neq j$  dengan persamaan (2.41)

$$R_{1,2} = \frac{S_1 + S_2}{M_{1,2}} = \frac{98,88 + 203,81}{2232,15} = 0,1356$$

$$R_{1,3} = \frac{S_1 + S_3}{M_{1,3}} = \frac{98,88 + 0,00}{1946,51} = 0,0508$$

$$R_{2,3} = \frac{S_2 + S_3}{M_{2,3}} = \frac{203,81 + 0,00}{4176,91} = 0,0488$$

- d. Menghitung nilai indeks *Davies-Bouldin* hasil klusterisasi menggunakan persamaan (2.40)

$$DB = \frac{1}{3} (0,1356 + 0,0508 + 0,0488) = 0,0784$$

### 3. Indeks *Calinski-Harabasz*

Evaluasi hasil pengelompokan BPR dengan indeks *Calinski-Harabasz* diperoleh dengan menghitung terlebih dahulu *sum of squares within cluster* atau jarak setiap objek data terhadap pusat kluster dan *sum of squares between cluster* atau jarak antar pusat kluster. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Calinski-Harabasz* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Calinski-Harabasz* hasil klusterisasi algoritma *k-means* 3 kluster dari data BPR tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung *sum of squares within cluster* atau *SSW* sesuai persamaan (2.45)

$$SSW = \sum_{i=1}^k \sum_{j=1}^{n_k} \|x_{jk} - c_k\|^2 = \sum_{i=1}^k \left( \sum_{j=1}^{n_1} \|x_{j1} - c_1\|^2 + \sum_{j=1}^{n_2} \|x_{j2} - c_2\|^2 + \sum_{j=1}^{n_3} \|x_{j3} - c_3\|^2 \right)$$

$$SSW = ((9788,03 + 9778,20) + (56571,21 + \dots + 1431,06) + (0,00))$$

$$SSW = (19556,23) + (1162334,38) + (0,00) = 1181890,61$$

b. Menghitung *sum of squares between cluster* atau *SSB* sesuai persamaan (2.46)

$$SSB = \sum_{i=1}^k n_k \times \|c_k - c\|^2 = (n_1 \times \|c_1 - c\|^2) + (n_2 \times \|c_2 - c\|^2) + (n_3 \times \|c_3 - c\|^2)$$

$$SSB = (2 \times 2129,30) + (81 \times 10579,97) + (1 \times 16597987,35) = 17459223,58$$

c. Menghitung nilai indeks *Calinski-Harabasz* hasil klusterisasi sesuai persamaan (2.44)

$$CH = \frac{SSB}{SSW} \times \frac{(n - k)}{(k - 1)} = \frac{17459223,58}{1181890,61} \times \frac{(84 - 3)}{(3 - 1)} = 598,2775$$

Evaluasi hasil *clustering* algoritma *k-means* dalam pengelompokan BPR menggunakan indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz* secara lengkap disajikan pada Tabel 4.10. Kemudian dilakukan pemilihan hasil klusterisasi BPR terbaik berdasarkan nilai validasi *Sil* paling mendekati 1 (Zhao, dkk., 2023), *DB* terkecil (Davies dan Bouldin, 1979), dan *CH* terbesar (Ros, dkk., 2023).

**Tabel 4.10** Evaluasi Hasil Klusterisasi BPR dengan Algoritma *K-means*

Bank	z-score	Jumlah Kluster	Nilai Validasi		
			<i>Sil</i>	<i>DB</i>	<i>CH</i>
BPR	Tanpa	3	0,9157	0,0784	598,2775
		4	0,5527	0,4331	645,2175
		5	0,5494	0,5052	172,0722
	Dengan	3	0,3348	1,1044	23,7591
		4	0,3242	0,9781	23,9929
		5	0,3267	0,9685	25,3000

Berdasarkan Tabel 4.10, analisis *clustering* BPR dengan algoritma *k-means* menghasilkan pengelompokan terbaik saat kluster berjumlah 3 kelompok dengan data tanpa proses standarisasi. *Centroid* atau pusat kluster dari hasil klusterisasi terbaik tersebut disajikan pada Tabel 4.11.

**Tabel 4.11** Pusat Kluster BPR Terbaik dengan *K-means*

Kluster	Variabel						Jumlah Anggota Kluster
	NPL	LDR	BOPO	ROA	NIM	KPMM	
1	2,91	2366,51	80,69	3,77	19,30	211,30	2
2	12,15	137,88	94,80	1,26	12,22	87,42	81
3	0,00	4312,90	95,91	0,82	4,32	212,25	1

Berdasarkan nilai *centroid* pada Tabel 4.11, kemudian dihitung  $d_{c_j, x_i}$  yakni jarak untuk tiap kombinasi data  $x_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan (2.20). Hasil perhitungan jarak beberapa data BPR terhadap semua *centroid* yang terbentuk disajikan pada Tabel 4.12. Jarak tiap kombinasi data BPR dan *centroid* secara lengkap dilampirkan pada Lampiran 3.

**Tabel 4.12** Data Jarak dari Hasil Klusterisasi BPR Terbaik dengan *K-means*

Nama BPR	$d_{c_1, x_n}$	$d_{c_2, x_n}$	$d_{c_3, x_n}$
PT BPR Balongpanggung Sentosa	1997,39	237,85	3942,89
PT BPR Dana Rajabally	98,88	2323,30	1858,53

**Tabel 4.12** Data Jarak dari Hasil Klasterisasi BPR Terbaik dengan *K-means* (Lanjutan)

	⋮	⋮	⋮	⋮
PT BPR Delta Lamongan	2245,07	19,09	4190,10	
PT BPR Mitra Dhnaceswara	2227,24	37,82	4172,75	

Sesuai persamaan (2.21) tiap data BPR dikelompokkan ke salah satu klaster berdasarkan jarak  $d_{c_j, x_i}$  terdekat. Sebagai contoh, PT BPR Balongpanggung Sentosa dikelompokkan ke klaster 2 karena memiliki jarak paling minimum yakni 237,85 dibandingkan ke dua klaster lainnya. Sedangkan PT BPR Dana Rajabally dikelompokkan ke klaster 1 karena memiliki jarak paling minimum yakni 98,88 dibandingkan ke dua klaster lainnya. Hasil klasterisasi BPR secara lengkap dapat dilihat pada Tabel 4.13.

**Tabel 4.13** Hasil Klasterisasi BPR Terbaik dengan *K-means*

Klaster	Anggota Klaster	
	Nama Kabupaten/Kota	Nama Bank Perkreditan Rakyat
1 (2 anggota)	Kabupaten Gresik	BPR Dana Rajabally, BPR Rajadana Menganti
	Kabupaten Gresik	PT BPR Balongpanggung Sentosa, Perumda BPR Bank Gresik, PT BPR Bank Bumi Sanggabuana, PT BPR Intan Kita, PT BPR Aneka Dana Sejahtera, PT BPR Kebomas, PT BPR Intan Nasional, PT BPR Mitra Cemawis Mandiri, PT BPR Lestari Nusantara Indonesia
	Kabupaten Bangkalan	Perumda BPR Bangkalan, PT BPR Dana Kerja Putra
	Kabupaten Mojokerto	PT BPR Arta Swasembada, PT BPR Arta Haksaprima, KSP BPR Sendang Harta Sejahtera, PT BPR Bumi Jaya, PT BPR Mojosari Pahalpacto, PT BPR Karunia Berkat Intidana, PT BPR Arta Bangsa Utama, PT BPR Puriseger Sentosa
	Kota Mojokerto	PT BPR Majatama Perseroda, PT BPR Kurnia Dadi Arta
2 (81 anggota)	Kota Surabaya	PT BPR Jawa Timur, PT BPR Danamitra Surya, PT BPR Kirana Indonesia, PT BPR Prima Kredit Utama, PT BPR Danamas, PT BPR Guna Yatra, PT BPR Kosanda, PT BPR Bintang Mitra Indonesia, PT BPR Central Niaga, PT BPR Bina Kharisma Insani, PT BPR Surya Arthaguna Abadi, PT BPR Sili Corp Bank, PT BPR Karyaperdana Sejahtera, PT BPR Surya Artha Utama Perseroda, PT BPR Prima Master Bank
	Kabupaten Sidoarjo	PT BPR Krian Nusantara, PT BPR Srikaya, PT BPR Artha Buana, PT BPR Bank Benta Tesa, PT BPR Taman Dhana, PT BPR Arta Waru Surya, PT BPR Satyadhana Artha, PT BPR Buana Dana Makmur, PT BPR Sinardana Buana, PT BPR Bandataman, PT BPR Sarana Sukses, PT BPR Berkat Cahaya Artha, PT BPR Abrin Centra Artha, PT BPR Megakerta Swadiri, PT BPR Dinar Pusaka, PT BPR Bank Ima, PT BPR Gema Nusa, PT BPR Toelangan Dasa Nusantara, PT BPR Sari Dana Indonesia, PT BPR Taman Artha Kencana, PT BPR Padat Ganda, PT BPR Sahabat Mitra Artha, PT BPR Anglomas Indah, PT BPR Dana Raya Jawa Timur, PT BPR Dirgadhana Arthamas, PT BPR Mahkota Krian Wijaya, PT BPR Wutama Artha Sejahtera, PT BPR Sentra Dana Makmur, PT BPR Djojo Mandiri Raya,

Tabel 4.13 Hasil Klasterisasi BPR Terbaik dengan *K-Means* (Lanjutan)

Klaster	Nama Kabupaten/Kota	Anggota Klaster
		Nama Bank Perkreditan Rakyat
		PT BPR Puridana Arthamas, PT BPR Andalan Daerah, PT BPR Candisaka Arta, PT BPR Mitra Majujaya Mandiri, PT BPR Artamulya Bumimukti, PT BPR Buduran Deltapurnam, PT BPR Bumi Gora Jaya, PT BPR Delta Artha Perseroda, PT BPR Wiradhana Putramas, PT BPR Jati Lestari
	Kabupaten Lamongan	Perumda BPR Bank Daerah Lamongan, PT BPR Nusamba Brondong, PT BPR Rukun Karya Sari, PT BPR Ulintha Ganda, PT BPR Delta Lamongan, PT BPR Mitra Dhanaceswara
3 (1 anggota)	Kota Surabaya	Permata Artha Surya

Pada pengelompokan BPR menjadi 3 klaster dari data tanpa proses standarisasi dengan algoritma *k-means*, klaster pertama beranggotakan 2 BPR, klaster kedua terdiri dari 81 BPR, dan 1 BPR sisanya termasuk dalam klaster ketiga.

#### 4.5.2. BPRS

Berdasarkan jumlah klaster yang dihasilkan pada penelitian oleh Puspita dan Pratiwi (2016) serta Guna (2023) dan juga jumlah data BPRS yang berjumlah kurang dari 10, jumlah klaster yang digunakan untuk pengelompokan BPRS adalah 2 dan 3. Selanjutnya, analisis *clustering* dengan algoritma *k-means* dilakukan dengan tahapan sebagai berikut,

- Menginisiasi indeks iterasi awal  $\eta = 1$  dan jumlah iterasi maksimum  $\eta_{max} = 100$  (Borlea dkk., 2021; Yohannes, 2016).
- Menginisiasi matriks *centroid* awal secara acak sesuai persamaan (2.19). Ukuran matriks *centroid* disesuaikan dengan jumlah variabel yang dimiliki dan jumlah klaster yang ingin dibentuk. Sebagai contoh dalam pengelompokan BPRS menjadi 2 klaster, matriks *centroid* memiliki ukuran  $[4 \times 2]$  seperti berikut,

$$C^{(1)} = \begin{bmatrix} 8,83 & 44,06 \\ 316,67 & 94,51 \\ 10,34 & 7,42 \\ 54,46 & 30,88 \end{bmatrix}$$

- Menghitung jarak  $d_{c_j, x_i}$  untuk tiap kombinasi objek  $x_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan (2.20)  
Sebagai contoh untuk data BPRS ke-1 yakni,

$$x_1 = [10,50 \quad 88,99 \quad 9,14 \quad 23,33]$$

Jarak  $c_1$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$\begin{aligned} d_{c_1, x_1} &= \sqrt{(10,50 - 8,83)^2 + (88,99 - 316,67)^2 + (9,14 - 10,34)^2 + (23,33 - 54,46)^2} \\ &= 229,81 \end{aligned}$$

Jarak  $c_2$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$\begin{aligned} d_{c_2, x_1} &= \sqrt{(10,50 - 44,06)^2 + (88,99 - 94,51)^2 + (9,14 - 7,42)^2 + (23,33 - 30,88)^2} \\ &= 34,88 \end{aligned}$$

Setelah menghitung seluruh jarak  $d_{c_j, x_i}$  untuk tiap kombinasi objek dan *centroid*, diperoleh matriks jarak berukuran  $[7 \times 2]$  sebagai berikut

$$D^{(1)} = \begin{bmatrix} 229,81 & 34,88 \\ \vdots & \vdots \\ 0,00 & 226,19 \\ 196,14 & 45,66 \end{bmatrix}$$

d. Menetapkan semua objek data ke salah satu  $k$  kluster berdasarkan jarak  $d_{c_j, x_i}$  terdekat sebagaimana persamaan (2.21).

Sebagai contoh untuk data BPRS ke-1 ( $x_1$ ), jarak  $d_{c_j, x_1}$  terdekat adalah 34,88. Sehingga  $x_1$  dikelompokkan ke dalam kluster 2.

e. Menghitung *centroid* baru untuk setiap kluster yakni  $c_j^{(\eta+1)}$  berdasarkan nilai rata-rata dari semua objek data yang termasuk dalam sebuah kluster dengan persamaan (2.23).

Sebagai contoh, kluster 2 yang terdiri atas 6 objek data, *centroid* baru untuk variabel NPL dihitung dengan rumus sebagai berikut

$$c_{2_1}^{(2)} = \frac{1}{6} \sum_{x_i \in c_2^{(\eta)}} x_{i_1} = \frac{1}{6} (10,50 + 16,62 + \dots + 8,83 + 17,20) = 16,18$$

Setelah perhitungan seluruh *centroid* baru untuk tiap variabel dan tiap kluster, diperoleh matriks *centroid* baru sebagai berikut,

$$C^{(2)} = \begin{bmatrix} 8,83 & 16,18 \\ 316,67 & 111,53 \\ 10,34 & 9,16 \\ 54,46 & 36,96 \end{bmatrix}$$

f. Mengecek kriteria pemberhentian algoritma yakni persamaan (2.25) dan kemudian (2.27). Jika memenuhi, hasil kluster sesuai dengan persamaan (2.26). Jika tidak,  $\eta$  ditambah secara bertahap dan tahapan diulang dari langkah ke-c.

Berdasarkan kriteria pemberhentian persamaan (2.25),  $C^{(2)} = C^{(1)}$  tidak terpenuhi atau matriks *centroid* masih berubah setelah dua iterasi berturut-turut. Oleh karena itu, tahapan *clustering* diulang kembali dari langkah ke-c sampai menemukan hasil klusterisasi yang optimal dan memenuhi kriteria pemberhentian algoritma.

Setelah mendapatkan hasil klusterisasi untuk setiap jumlah kluster, hasil klusterisasi dievaluasi menggunakan nilai validitas *cluster* indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz*.

### 1. Indeks *Silhouette*

Evaluasi hasil pengelompokan BPRS dengan indeks *Silhouette* diperoleh dengan mendapatkan nilai indeks *Silhouette* per objek data terlebih dahulu. Kemudian nilai indeks *Silhouette* seluruh objek dalam *dataset* dihitung rata-ratanya agar didapatkan nilai indeks *Silhouette* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Silhouette* hasil klusterisasi algoritma *k-means* 2 kluster dari data BPRS tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

a. Untuk data BPRS ke-1 ( $x_1$ ) yang dikelompokkan ke kluster 2 beranggotakan 6 BPRS, dihitung rerata ketidaksamaan ( $a_1$ ) yakni rata-rata jarak  $x_1$  terhadap  $x_j$  lain pada kluster 2.

$$a_1 = \frac{\sum_{j=1}^{n_2} \|x_1 - x_j\|}{n_2 - 1}, j \neq 1$$

$$= \frac{\|x_1 - x_2\| + \dots + \|x_1 - x_6\|}{6 - 1} = \frac{23,26 + \dots + 46,43}{5} = 39,82$$

- b. Selanjutnya, menghitung rerata ketidaksamaan  $d(1, C)$  antara  $x_1$  pada kluster 2 terhadap semua  $x_i$  di kluster C yang mana C adalah semua kluster selain kluster 2. Nilai  $d(1, C_1)$  dimana kluster 1 terdiri atas 1 anggota adalah,

$$d(1, C_1) = \frac{\sum_{j=1}^{n_1} \|x_{1C_2} - x_{jC_1}\|}{n_1} = \frac{\|x_{1C_2} - x_{1C_1}\|}{1} = 229,81$$

- c. Setelah menghitung  $d(1, C)$  untuk semua kluster selain kluster 2, dipilih nilai minimum dari  $d(1, C)$  yang akan disebut sebagai  $b_1$ .

$$b_1 = \min(d(1, C_1)) = 229,81$$

- d. Kemudian nilai indeks *Silhouette* untuk data BPRS ke-1 ( $x_1$ ) dihitung dengan persamaan (2.39) sebagai berikut,

$$Sil_1 = \frac{(b_1 - a_1)}{\max(a_1, b_1)} = \frac{(229,81 - 39,82)}{\max(229,81 ; 39,82)} = 0,8267$$

- e. Terakhir nilai indeks *Silhouette* hasil klusterisasi algoritma *k-means* 2 kluster diperoleh dengan menghitung rata-rata  $Sil_i$  semua objek data.

$$Sil = \frac{1}{n} \sum_{i=1}^n Sil_i = \frac{1}{7} (0,8267 + \dots + 0,8128) = 0,6907$$

## 2. Indeks *Davies-Bouldin*

Evaluasi hasil pengelompokan BPRS dengan indeks *Davies-Bouldin* diperoleh dengan mendapatkan perhitungan rata-rata jarak setiap objek data terhadap pusat kluster dan jarak antar pusat kluster terlebih dahulu. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Davies-Bouldin* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Davies-Bouldin* hasil klusterisasi algoritma *k-means* 2 kluster dari data BPRS tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung nilai rata-rata jarak tiap objek data terhadap pusat klasternya ( $S_i$ ) untuk setiap kluster dengan persamaan (2.42)

$$S_1 = \frac{1}{n_1} \sum_{j=1}^{n_1} \|x_j - c_1\| = \frac{1}{1} (0,00) = 0,00$$

$$S_2 = \frac{1}{n_2} \sum_{j=1}^{n_2} \|x_j - c_2\| = \frac{1}{6} (26,94 + 21,23 + \dots + 21,78) = 26,17$$

- b. Menghitung jarak separasi antar kluster ( $M_{ij}$ ) untuk setiap pasangan *centroid* saat  $i \neq j$  sesuai persamaan (2.43)

$$M_{1,2} = \|c_1 - c_2\| = \sqrt{(8,83 - 16,18)^2 + \dots + (54,46 - 36,95)^2} = 206,02$$

- c. Menghitung nilai  $R_{ij}$  untuk setiap pasangan *centroid* saat  $i \neq j$  dengan persamaan (2.41)

$$R_{1,2} = \frac{S_1 + S_2}{M_{1,2}} = \frac{0,00 + 26,17}{206,02} = 0,1270$$

- d. Menghitung nilai indeks *Davies-Bouldin* hasil klusterisasi menggunakan persamaan (2.40)  
 $DB = 0,1270$

### 3. Indeks *Calinski-Harabasz*

Evaluasi hasil pengelompokan BPRS dengan indeks *Calinski-Harabasz* diperoleh dengan menghitung terlebih dahulu *sum of squares within cluster* atau jarak setiap objek data terhadap pusat kluster dan *sum of squares between cluster* atau jarak antar pusat kluster. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Calinski-Harabasz* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Calinski-Harabasz* hasil klusterisasi algoritma *k-means* 2 kluster dari data BPRS tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung *sum of squares within cluster* atau *SSW* sesuai persamaan (2.45)

$$SSW = \sum_{i=1}^k \sum_{j=1}^{n_k} \|x_{jk} - c_k\|^2 = \sum_{i=1}^k \left( \sum_{j=1}^{n_1} \|x_{j1} - c_1\|^2 + \sum_{j=1}^{n_2} \|x_{j2} - c_2\|^2 \right)$$

$$SSW = ((0,00) + (725,82 + \dots + 474,49)) = (0,00 + 4424,69) = 4424,69$$

- b. Menghitung *sum of squares between cluster* atau *SSB* sesuai persamaan (2.46)

$$SSB = \sum_{i=1}^k n_k \times \|c_k - c\|^2 = (n_1 \times \|c_1 - c\|^2) + (n_2 \times \|c_2 - c\|^2)$$

$$SSB = (1 \times 31184,50) + (6 \times 866,24) = 36380,90$$

- c. Menghitung nilai indeks *Calinski-Harabasz* hasil klusterisasi sesuai persamaan (2.44)

$$CH = \frac{SSB}{SSW} \times \frac{(n - k)}{(k - 1)} = \frac{36380,90}{4424,69} \times \frac{(7 - 2)}{(2 - 1)} = 41,11$$

Evaluasi hasil *clustering* algoritma *k-means* dalam pengelompokan BPRS menggunakan indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz* secara lengkap disajikan pada Tabel 4.14.

**Tabel 4.14** Evaluasi Hasil Klusterisasi BPRS dengan Algoritma *K-means*

Bank	z-score	Jumlah Kluster	Nilai Validasi		
			Sil	DB	CH
BPRS	Tanpa	2	0,6907	0,1270	41,1124
		3	0,2916	0,5821	42,1825
	Dengan	2	0,3449	0,9535	4,8282
		3	0,3122	0,6679	4,3206

Kemudian dilakukan pemilihan hasil klusterisasi BPR terbaik berdasarkan nilai validasi *Sil* paling mendekati 1 (Zhao, dkk., 2023), *DB* terkecil (Davies dan Bouldin, 1979), dan *CH* terbesar (Ros, dkk., 2023). Berdasarkan Tabel 4.14, analisis *clustering* BPRS dengan algoritma *k-means* menghasilkan pengelompokan terbaik saat kluster berjumlah 2 kelompok dengan data tanpa proses standarisasi. *Centroid* atau pusat kluster dari hasil klusterisasi terbaik tersebut disajikan pada Tabel 4.15.

**Tabel 4.15** Pusat Kluster BPRS Terbaik dengan *K-means*

Kluster	Variabel				Jumlah Anggota Kluster
	NPL	LDR	NI	KPMM	
1	8,83	316,67	10,34	54,46	1
2	16,18	111,53	9,16	36,96	6

Berdasarkan nilai *centroid* pada Tabel 4.15, kemudian dihitung  $d_{c_j, x_i}$  yakni jarak untuk tiap kombinasi data  $x_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan (2.20). Secara lebih lengkap, jarak tiap data BPRS terhadap seluruh *centroid* yang terbentuk disajikan pada Tabel 4.16.

**Tabel 4.16** Data Jarak dari Hasil Klasterisasi BPRS Terbaik dengan *K-means*

Nama BPRS	$d_{c_1, x_n}$	$d_{c_2, x_n}$
PT BPRS Amanah Sejahtera	229,81	28,58
PT BPRS Mandiri Mitra Sukses	210,29	24,23
PT BPRS Karya Mugi Sentosa	198,39	17,49
PT BPRS Baktimakmur Indah	226,19	33,95
PT BPRS Annisa Mukti	181,86	35,35
PT BPRS Unawi Barokah	0,00	205,79
PT BPRS Madinah	196,14	19,15

Sesuai persamaan (2.21) tiap data BPRS dikelompokkan ke salah satu klaster berdasarkan jarak  $d_{c_j, x_i}$  terdekat. Sebagai contoh, PT BPRS Amanah Sejahtera dikelompokkan ke klaster 2 karena memiliki jarak paling minimum yakni 28,58 dibandingkan terhadap klaster 1. Sedangkan PT BPRS Unawi Barokah dikelompokkan ke klaster 1 karena memiliki jarak paling minimum yakni 0,00 dibandingkan terhadap klaster 2. Hasil klasterisasi BPRS secara lengkap dapat dilihat pada Tabel 4.17.

**Tabel 4.17** Hasil Klasterisasi BPRS Terbaik dengan *K-means*

Kluster	Anggota Kluster	
	Nama Kabupaten/Kota	Nama Bank Pembiayaan Rakyat Syariah
1 (1 anggota)	Kabupaten Sidoarjo	PT BPRS Unawi Barokah
	Kabupaten Gresik	PT BPRS Amanah Sejahtera, PT BPRS Mandiri Mitra Sukses
2 (6 anggota)	Kota Surabaya	PT BPRS Karya Mugi Sentosa
	Kabupaten Sidoarjo	PT BPRS Baktimakmur Indah, PT BPRS Annisa Mukti
	Kabupaten Lamongan	PT BPRS Madinah

Pada pengelompokan BPRS menjadi 2 klaster dari data tanpa proses standarisasi dengan algoritma *k-means*, klaster pertama hanya beranggotakan 1 BPRS sedangkan klaster kedua terisi 6 BPRS lainnya.

#### 4.6. Klasterisasi Menggunakan Algoritma *Fuzzy C-means*

Dalam melakukan analisis *clustering*, digunakan data tanpa standarisasi dan data yang telah distandarisasi. Kemudian sama seperti algoritma *k-means*, sebelum melakukan *fuzzy c-means clustering* harus ditentukan terlebih dahulu jumlah klaster yang mewakili banyaknya kelompok yang akan terbentuk. Setelah melakukan analisis *clustering* sesuai dengan jumlah klaster yang ditentukan, setiap hasil klasterisasi akan dievaluasi menggunakan nilai indeks validitas *cluster Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz*. Terakhir, dilakukan pemilihan hasil klasterisasi terbaik untuk tiap jenis perbankan berdasarkan ketiga nilai indeks validitas *cluster*.

#### 4.6.1. BPR

Berdasarkan jumlah kluster yang dihasilkan pada penelitian oleh Puspita dan Pratiwi (2016), Pristyandini (2018), dan juga Guna (2023) serta jumlah peringkat pada Peraturan OJK No.3 Tahun 2022 tentang Penilaian Tingkat Kesehatan BPR dan BPRS, jumlah kluster yang digunakan untuk pengelompokan BPR adalah 3, 4, dan 5. Selanjutnya, analisis *clustering* dengan algoritma *fuzzy c-means* dilakukan dengan tahapan sebagai berikut,

- Menginisiasi parameter awal yang terdiri atas: indeks iterasi awal  $\eta = 1$ ; jumlah iterasi maksimum  $\eta_{max} = 100$ ; *fuzziness*  $m = 2$ ; dan nilai konvergensi  $\varepsilon = 10^{-5}$  (Borlea dkk., 2021; Yohannes, 2016).
- Menginisiasi matriks *centroid* awal secara acak sesuai persamaan (2.19). Ukuran matriks *centroid* disesuaikan dengan jumlah variabel yang dimiliki dan jumlah kluster yang ingin dibentuk. Sebagai contoh dalam pengelompokan BPR menjadi 3 kluster, matriks *centroid* memiliki ukuran  $[6 \times 3]$  seperti berikut,

$$\mathbf{C}^{(1)} = \begin{bmatrix} 19,20 & 0,00 & 1,02 \\ 182,48 & 4312,90 & 2277,97 \\ 106,94 & 95,91 & 90,16 \\ 1,27 & 0,82 & 2,31 \\ 16,46 & 4,32 & 22,28 \\ 94,62 & 212,25 & 168,47 \end{bmatrix}$$

- Menghitung jarak  $d_{c_j, x_i}$  untuk tiap kombinasi objek  $x_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan (2.20)  
Sebagai contoh untuk data BPR ke-1 yakni,

$$\mathbf{x}_1 = [14,60 \quad 371,26 \quad 66,53 \quad 9,08 \quad 23,07 \quad 120,89]$$

Jarak  $c_1$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$d_{c_1, x_1} = \sqrt{(14,60 - 19,20)^2 + (371,26 - 182,48)^2 + (66,53 - 106,94)^2 + (9,08 - 1,27)^2 + (23,07 - 16,46)^2 + (120,89 - 94,62)^2} = 195,16$$

Jarak  $c_2$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$d_{c_2, x_1} = \sqrt{(14,60 - 0,00)^2 + (371,26 - 4312,90)^2 + (66,53 - 95,91)^2 + (9,08 - 0,82)^2 + (23,07 - 4,32)^2 + (120,89 - 212,25)^2} = 3942,89$$

Jarak  $c_3$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$d_{c_3, x_1} = \sqrt{(14,60 - 1,02)^2 + (371,26 - 2277,97)^2 + (66,53 - 90,16)^2 + (9,08 - 2,31)^2 + (23,07 - 22,28)^2 + (120,89 - 168,47)^2} = 1907,51$$

- Membentuk matriks keanggotaan  $\mu_c^{(\eta)}$  seperti pada persamaan (2.31). Matriks tersebut terdiri atas elemen-elemen  $\mu_{c_j}^{(\eta)}(x_i)$  yang mewakili derajat keanggotaan sebuah objek  $x_i$  ke dalam kluster  $c_j$  yang dihitung dengan persamaan (2.29). Sebagai contoh untuk data BPR ke-1,  $\mu_{c_j}^{(\eta)}(x_1)$  untuk tiap kluster adalah sebagai berikut,

$$\mu_{c_1}^{(1)}(x_1) = \frac{\left(\frac{1}{d_{c_1, x_1}}\right)^{\frac{2}{2-1}}}{\left(\frac{1}{d_{c_1, x_1}}\right)^{\frac{2}{2-1}} + \left(\frac{1}{d_{c_2, x_1}}\right)^{\frac{2}{2-1}} + \left(\frac{1}{d_{c_3, x_1}}\right)^{\frac{2}{2-1}}} = \frac{\left(\frac{1}{195,16}\right)^2}{\left(\frac{1}{195,16}\right)^2 + \left(\frac{1}{3942,89}\right)^2 + \left(\frac{1}{1907,51}\right)^2}$$

$$= \frac{2,6 \times 10^{-5}}{(2,6 \times 10^{-5}) + (6,4 \times 10^{-8}) + (2,7 \times 10^{-7})} = 0,9872$$

$$\mu_{c_2}^{(1)}(x_1) = \frac{6,4 \times 10^{-8}}{(2,6 \times 10^{-5}) + (6,4 \times 10^{-8}) + (2,7 \times 10^{-7})} = 0,0024$$

$$\mu_{c_3}^{(1)}(x_1) = \frac{2,7 \times 10^{-7}}{(2,6 \times 10^{-5}) + (6,4 \times 10^{-8}) + (2,7 \times 10^{-7})} = 0,0103$$

Setelah menghitung seluruh derajat keanggotaan  $\mu_{c_j}^{(\eta)}(x_i)$  untuk tiap kombinasi objek dan kluster, diperoleh matriks keanggotaan  $\mu_C^{(\eta)}$  pada iterasi pertama dengan ukuran  $[84 \times 3]$  sebagai berikut

$$\mu_C^{(1)} = \begin{bmatrix} 0,9872 & 0,0024 & 0,0103 \\ 0,0074 & 0,0111 & 0,9815 \\ \vdots & \vdots & \vdots \\ 0,9989 & 0,0002 & 0,0008 \\ 0,9990 & 0,0002 & 0,0008 \end{bmatrix}$$

- e. Menghitung *centroid* baru untuk setiap kluster yakni  $c_j^{(\eta+1)}$  berdasarkan persamaan (2.32). Sebagai contoh, kluster 1 yang terdiri atas 81 objek data, *centroid* baru untuk variabel NPL dihitung dengan rumus sebagai berikut

$$c_{1_1}^{(2)} = \frac{\sum_{i=1}^n \{[\mu_{c_j}^{(\eta)}(x_i)]^m x_{i_1}\}}{\sum_{i=1}^n [\mu_{c_j}^{(\eta)}(x_i)]^m} = \frac{\{0,9872^2 \times 14,60\} + \dots + \{0,9990^2 \times 6,81\}}{(0,9872^2 + \dots + 0,9990^2)} = 12,19$$

Setelah perhitungan seluruh *centroid* baru untuk tiap variabel dan tiap kluster, diperoleh matriks *centroid* baru sebagai berikut,

$$C^{(2)} = \begin{bmatrix} 12,19 & 0,01 & 3,05 \\ 134,32 & 4307,93 & 2332,22 \\ 94,79 & 95,91 & 81,13 \\ 1,26 & 0,82 & 3,69 \\ 12,23 & 4,33 & 19,26 \\ 86,88 & 212,09 & 207,25 \end{bmatrix}$$

- f. Membentuk matriks keanggotaan baru untuk iterasi selanjutnya  $\mu_C^{(\eta+1)}$  seperti yang dilakukan pada langkah ke-d. Matriks keanggotaan baru  $\mu_C^{(\eta)}$  pada iterasi kedua berukuran  $[84 \times 3]$  adalah sebagai berikut

$$\mu_C^{(2)} = \begin{bmatrix} 0,9815 & 0,0040 & 0,0148 \\ 0,0032 & 0,0050 & 0,9918 \\ \vdots & \vdots & \vdots \\ 0,9999 & 1,7 \times 10^{-5} & 5,9 \times 10^{-5} \\ 0,9996 & 8,6 \times 10^{-5} & 0,0003 \end{bmatrix}$$

- g. Mengecek kriteria pemberhentian algoritma yakni persamaan (2.33) dan kemudian (2.27). Jika memenuhi, hasil kluster sesuai dengan persamaan (2.34). Jika tidak,  $\eta$  ditambah secara bertahap dan tahapan diulang dari langkah ke-e.

Berdasarkan kriteria pemberhentian persamaan (2.33),  $|\mu_C^{(2)} - \mu_C^{(1)}| < \varepsilon$  tidak terpenuhi atau matriks keanggotaan masih berubah setelah dua iterasi berturut-turut. Oleh karena itu, tahapan *clustering* diulang kembali dari langkah ke-e sampai menemukan hasil klusterisasi yang optimal dan memenuhi kriteria pemberhentian algoritma.

Setelah mendapatkan hasil klusterisasi untuk setiap jumlah kluster, hasil klusterisasi dievaluasi menggunakan nilai validitas *cluster* indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz*.

### 1. Indeks *Silhouette*

Evaluasi hasil pengelompokan BPR dengan indeks *Silhouette* diperoleh dengan mendapatkan nilai indeks *Silhouette* per objek data terlebih dahulu. Kemudian nilai indeks *Silhouette* seluruh objek dalam dataset dihitung rata-ratanya agar didapatkan nilai indeks *Silhouette* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Silhouette fuzzy* hasil klusterisasi algoritma *fuzzy c-means* 3 kluster dari data BPR tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Untuk data BPR ke-1 ( $x_1$ ) yang dikelompokkan ke kluster 1 beranggotakan 81, dihitung rerata ketidaksamaan ( $a_1$ ) yakni rata-rata jarak  $x_1$  terhadap  $x_i$  lain pada kluster 1.

$$\begin{aligned} a_1 &= \frac{\sum_{j=1}^{n_1} (\mu_{c_1}(x_j))^m \times \|x_1 - x_j\|}{\sum_{j=1}^{n_1} (\mu_{c_1}(x_j))^m}, j \neq 1 \\ &= \frac{\{(\mu_{c_1}(x_2))^2 \times \|x_1 - x_2\|\} + \dots + \{(\mu_{c_1}(x_{81}))^2 \times \|x_1 - x_{81}\|\}}{(\mu_{c_1}(x_1))^2 + \dots + (\mu_{c_1}(x_{81}))^2} \\ &= \frac{\{0,9995 \times 273,29\} + \dots + \{0,9992 \times 230,26\}}{0,9995 + \dots + 0,9992} = 265,60 \end{aligned}$$

- b. Selanjutnya, menghitung rerata ketidaksamaan  $d(1, C)$  antara  $x_1$  pada kluster 1 terhadap semua  $x_i$  di kluster C yang mana C adalah semua kluster selain kluster 1. Nilai  $d(1, C_2)$  dimana kluster 2 terdiri atas 2 anggota adalah,

$$\begin{aligned} d(1, C_2) &= \frac{\sum_{j=1}^{n_2} (\mu_{c_2}(x_{jC_2}))^m \times \|x_{1C_1} - x_{jC_2}\|}{\sum_{j=1}^{n_2} (\mu_{c_2}(x_{jC_2}))^m} \\ &= \frac{\{(\mu_{c_2}(x_{1C_2}))^2 \times \|x_{1C_1} - x_{1C_2}\|\} + \{(\mu_{c_2}(x_{2C_2}))^2 \times \|x_{1C_1} - x_{2C_2}\|\}}{(\mu_{c_2}(x_{1C_2}))^2 + (\mu_{c_2}(x_{2C_2}))^2} \\ &= \frac{\{0,9836 \times 2088,09\} + \{0,9958 \times 1907,51\}}{0,9836 + 0,9958} = 1997,24 \end{aligned}$$

Sedangkan nilai  $d(1, C_3)$  dimana kluster 3 terdiri dari 1 anggota adalah,

$$d(1, C_3) = \frac{(\mu_{c_3}(x_{1C_3}))^2 \times \|x_{1C_1} - x_{1C_3}\|}{(\mu_{c_3}(x_{1C_3}))^2} = \frac{0,9999 \times 3942,89}{0,9999} = 3942,89$$

- c. Setelah menghitung  $d(1, C)$  untuk semua kluster selain kluster 1, dipilih nilai minimum dari  $d(1, C)$  yang akan disebut sebagai  $b_1$ .

$$b_1 = \min(d(1, C_2); d(1, C_3)) = \min(1997,24 ; 3942,89) = 1997,24$$

- d. Kemudian nilai indeks *Silhouette fuzzy* untuk data BPR ke-1 ( $x_1$ ) dihitung dengan

persamaan (2.39) sebagai berikut,

$$Sil_1 = \frac{(b_1 - a_1)}{\max(a_1, b_1)} = \frac{(1997,24 - 262,23)}{\max(1997,24 ; 262,23)} = 0,8670$$

- e. Terakhir nilai indeks *Silhouette* hasil klusterisasi algoritma *fuzzy c-means* 3 kluster diperoleh dengan menghitung rata-rata  $Sil_i$  semua objek data.

$$Sil = \frac{1}{n} \sum_{i=1}^n Sil_i = \frac{1}{84} (0,8670 + \dots + 0,9469) = 0,9788$$

## 2. Indeks *Davies-Bouldin*

Evaluasi hasil pengelompokan BPR dengan indeks *Davies-Bouldin* diperoleh dengan mendapatkan perhitungan rata-rata jarak setiap objek data terhadap pusat kluster dan jarak antar pusat kluster terlebih dahulu. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Davies-Bouldin* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Davies-Bouldin* hasil klusterisasi algoritma *fuzzy c-means* 3 kluster dari data BPR tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung nilai rata-rata jarak tiap objek data terhadap pusat klusternya ( $S_i$ ) untuk setiap kluster dengan persamaan (2.42)

$$S_1 = \frac{1}{n_1} \sum_{j=1}^{n_1} \|x_j - c_1\| = \frac{1}{81} (241,98 + 32,51 + \dots + 38,88) = 194,83$$

$$S_2 = \frac{1}{n_2} \sum_{j=1}^{n_2} \|x_j - c_2\| = \frac{1}{2} (132,08 + 67,34) = 99,71$$

$$S_3 = \frac{1}{n_3} \sum_{j=1}^{n_3} \|x_j - c_3\| = \frac{1}{1} (5,73) = 5,73$$

- b. Menghitung jarak separasi antar kluster ( $M_{ij}$ ) untuk setiap pasangan *centroid* saat  $i \neq j$  sesuai persamaan (2.43)

$$M_{1,2} = \|c_1 - c_2\| = \sqrt{(12,17 - 3,08)^2 + \dots + (86,80 - 207,53)^2} = 2201,55$$

$$M_{1,3} = \|c_1 - c_3\| = \sqrt{(12,17 - 0,01)^2 + \dots + (86,60 - 212,25)^2} = 4175,32$$

$$M_{2,3} = \|c_2 - c_3\| = \sqrt{(3,08 - 0,01)^2 + \dots + (207,53 - 212,25)^2} = 1975,38$$

- c. Menghitung nilai  $R_{ij}$  untuk setiap pasangan *centroid* saat  $i \neq j$  dengan persamaan (2.41)

$$R_{1,2} = \frac{S_1 + S_2}{M_{1,2}} = \frac{194,83 + 99,71}{2201,55} = 0,1338$$

$$R_{1,3} = \frac{S_1 + S_3}{M_{1,3}} = \frac{194,83 + 5,73}{4175,32} = 0,0480$$

$$R_{2,3} = \frac{S_2 + S_3}{M_{2,3}} = \frac{99,71 + 5,73}{1975,38} = 0,0534$$

- d. Menghitung nilai indeks *Davies-Bouldin* hasil klusterisasi menggunakan persamaan (2.40)

$$DB = \frac{1}{3} (0,1338 + 0,0480 + 0,0534) = 0,0784$$

### 3. Indeks *Calinski-Harabasz*

Evaluasi hasil pengelompokan BPR dengan indeks *Calinski-Harabasz* diperoleh dengan menghitung terlebih dahulu *sum of squares within cluster* atau jarak setiap objek data terhadap pusat kluster dan *sum of squares between cluster* atau jarak antar pusat kluster. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Calinski-Harabasz* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Calinski-Harabasz* hasil klusterisasi algoritma *fuzzy c--means* 3 kluster dari data BPR tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

a. Menghitung *sum of squares within cluster* atau *SSW* sesuai persamaan (2.45)

$$SSW = \sum_{i=1}^k \sum_{j=1}^{n_k} \|x_{jk} - c_k\|^2 = \sum_{i=1}^k \left( \sum_{j=1}^{n_1} \|x_{j1} - c_1\|^2 + \sum_{j=1}^{n_2} \|x_{j2} - c_2\|^2 + \sum_{j=1}^{n_3} \|x_{j3} - c_3\|^2 \right)$$

$$SSW = ((58555,94 + \dots + 1511,38) + (17444,60 + 4534,44) + (32,88))$$

$$SSW = (1692968,07) + (21979,04) + (32,88) = 1714979,99$$

b. Menghitung *sum of squares between cluster* atau *SSB* sesuai persamaan (2.46)

$$SSB = \sum_{i=1}^k n_k \times \|c_k - c\|^2 = (n_1 \times \|c_1 - c\|^2) + (n_2 \times \|c_2 - c\|^2) + (n_3 \times \|c_3 - c\|^2)$$

$$SSB = (81 \times 107,01) + (2 \times 4387101,50) + (1 \times 16551300,62) = 25334171,42$$

c. Menghitung nilai indeks *Calinski-Harabasz* hasil klusterisasi sesuai persamaan (2.44)

$$CH = \frac{SSB}{SSW} \times \frac{(n - k)}{(k - 1)} = \frac{25334171,42}{1714979,99} \times \frac{(84 - 3)}{(3 - 1)} = 598,2775$$

Evaluasi hasil *clustering* algoritma *fuzzy c-means* dalam pengelompokan BPR menggunakan indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz* secara lengkap disajikan pada Tabel 4.18.

**Tabel 4.18** Evaluasi Hasil Klusterisasi BPR dengan Algoritma *Fuzzy C-means*

Bank	<i>z-score</i>	Jumlah Kluster	Nilai Validasi		
			<i>Sil</i>	<i>DB</i>	<i>CH</i>
BPR	Tanpa	3	0,9788	0,0784	598,2775
		4	0,7263	0,5032	619,6319
		5	0,7140	0,4715	706,2614
	Dengan	3	0,3239	1,6944	17,3322
		4	0,2416	1,5273	16,4171
		5	0,2482	1,6871	13,7156

Kemudian dilakukan pemilihan hasil klusterisasi BPR terbaik berdasarkan nilai validasi *Sil* paling mendekati 1 (Zhao, dkk., 2023), *DB* terkecil (Davies dan Bouldin, 1979), dan *CH* terbesar (Ros, dkk., 2023). Berdasarkan Tabel 4.18, analisis *clustering* BPR dengan algoritma *fuzzy c-means* menghasilkan pengelompokan terbaik saat kluster berjumlah 3 kelompok dengan data tanpa proses standarisasi. *Centroid* atau pusat kluster dari hasil klusterisasi terbaik tersebut disajikan pada Tabel 4.19.

**Tabel 4.19** Pusat Kluster BPR Terbaik dengan *Fuzzy C-means*

Kluster	Variabel						Jumlah Anggota Kluster
	NPL	LDR	BOPO	ROA	NIM	KPMM	
1	12,17	133,75	94,80	1,26	12,22	86,80	81
2	3,08	2331,91	81,03	3,70	19,22	207,53	2
3	0,02	4307,17	95,91	0,82	4,34	212,04	1

Berdasarkan nilai *centroid* pada Tabel 4.19, kemudian dihitung  $\mu_{c_j}^{(\eta)}(x_i)$  atau derajat keanggotaan setiap kombinasi data  $x_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan (2.29). Hasil perhitungan derajat keanggotaan beberapa data BPR terhadap seluruh *centroid* yang terbentuk disajikan pada Tabel 4.20. Derajat keanggotaan tiap kombinasi data BPR dan *centroid* secara lengkap dilampirkan pada Lampiran 4.

**Tabel 4.20** Derajat Keanggotaan Hasil Klasterisasi BPR Terbaik dengan *Fuzzy C-means*

Nama BPR	$\mu_{c_1}(x_n)$	$\mu_{c_2}(x_n)$	$\mu_{c_3}(x_n)$
PT BPR Balongpanggung Sentosa	0,98137	0,01492	0,00371
PT BPR Dana Rajabally	0,00319	0,99177	0,00504
⋮	⋮	⋮	⋮
PT BPR Delta Lamongan	0,99993	0,00006	0,00002
PT BPR Mitra Dhnaceswara	0,99960	0,00031	0,00009

Derajat keanggotaan pada Tabel 4.20 dapat diartikan sebagai kecenderungan suatu objek data dikelompokkan ke dalam suatu kluster tertentu. Sebagai contoh, PT BPR Balongpanggung Sentosa berpeluang sebesar 0,9814 masuk ke kluster 1; 0,0194 masuk ke kluster 2; sedangkan ke dalam kluster 3 data hanya berpeluang sebesar 0,0037. Oleh karenanya, data pertama secara *hard clustering* dapat dikelompokkan ke dalam kluster 1. Sedangkan PT BPR Dana Rajabally dapat dikelompokkan ke kluster 2 karena memiliki derajat keanggotaan terhadap kluster 2 sebesar 0,9918 yang mana nilainya paling besar dibandingkan derajat keanggotaan terhadap dua kluster lainnya. Hasil klasterisasi BPR secara lengkap dapat dilihat pada Tabel 4.21.

**Tabel 4.21** Hasil Klasterisasi BPR Terbaik dengan *Fuzzy C-means*

Kluster	Nama Kabupaten/Kota	Anggota Kluster
		Nama Bank Perkreditan Rakyat
1 (81 anggota)	Kabupaten Gresik	PT BPR Balongpanggung Sentosa, Perumda BPR Bank Gresik, PT BPR Bank Bumi Sanggabuana, PT BPR Intan Kita, PT BPR Aneka Dana Sejahtera, PT BPR Kebomas, PT BPR Intan Nasional, PT BPR Mitra Cemawis Mandiri, PT BPR Lestari Nusantara Indonesia
	Kabupaten Bangkalan	Perumda BPR Bangkalan, PT BPR Dana Kerja Putra
	Kabupaten Mojokerto	PT BPR Arta Swasembada, PT BPR Arta Haksaprima, KSP BPR Sendang Harta Sejahtera, PT BPR Bumi Jaya, PT BPR Mojosari Pahalpacto, PT BPR Karunia Berkat Intidana, PT BPR Arta Bangsal Utama, PT BPR Puriseger Sentosa
	Kota Mojokerto	PT BPR Majatama Perseroda, PT BPR Kurnia Dadi Arta
	Kota Surabaya	PT BPR Jawa Timur, PT BPR Danamitra Surya, PT BPR Kirana Indonesia, PT BPR Prima Kredit Utama, PT BPR Danamas, PT BPR Guna Yatra, PT BPR Kosanda, PT BPR Bintang Mitra Indonesia, PT BPR Central Niaga,

Tabel 4.21 Hasil Klasterisasi BPR Terbaik dengan *Fuzzy C-means* (Lanjutan)

Klaster	Nama Kabupaten/Kota	Anggota Klaster
		Nama Bank Perkreditan Rakyat
		PT BPR Surya Arthaguna Abadi, PT BPR Sili Corp Bank, PT BPR Karyaperdana Sejahtera, PT BPR Surya Artha Utama Perseroda, PT BPR Prima Master Bank
	Kabupaten Sidoarjo	PT BPR Krian Nusantara, PT BPR Srikaya, PT BPR Artha Buana, PT BPR Bank Benta Tesa, PT BPR Taman Dhana, PT BPR Arta Waru Surya, PT BPR Satyadhana Artha, PT BPR Buana Dana Makmur, PT BPR Sinardana Buana, PT BPR Bandataman, PT BPR Sarana Sukses, PT BPR Berkat Cahaya Artha, PT BPR Abrin Centra Artha, PT BPR Megakerta Swadiri, PT BPR Dinar Pusaka, PT BPR Bank Ima, PT BPR Gema Nusa, PT BPR Toelangan Dasa Nusantara, PT BPR Sari Dana Indonesia, PT BPR Taman Artha Kencana, PT BPR Padat Ganda, PT BPR Sahabat Mitra Artha, PT BPR Anglomas Indah, PT BPR Dana Raya Jawa Timur, PT BPR Dirgadhana Arthamas, PT BPR Mahkota Krian Wijaya, PT BPR Wutama Artha Sejahtera, PT BPR Sentra Dana Makmur, PT BPR Djojo Mandiri Raya, PT BPR Puridana Arthamas, PT BPR Andalan Daerah, PT BPR Candisaka Arta, PT BPR Mitra Majujaya Mandiri, PT BPR Artamulya Bumimukti, PT BPR Buduran Deltapurnam, PT BPR Bumi Gora Jaya, PT BPR Delta Artha Perseroda, PT BPR Wiradhana Putramas, PT BPR Jati Lestari
	Kabupaten Lamongan	Perumda BPR Bank Daerah Lamongan, PT BPR Nusamba Brondong, PT BPR Rukun Karya Sari, PT BPR Ulintha Ganda, PT BPR Delta Lamongan, PT BPR Mitra Dhanaceswara
2 (2 anggota)	Kabupaten Gresik	BPR Dana Rajabally, BPR Rajadana Menganti
3 (1 anggota)	Kota Surabaya	Permata Artha Surya

Pada pengelompokan BPR menjadi 3 klaster dari data tanpa proses standarisasi dengan algoritma *fuzzy c-means*, klaster pertama beranggotakan 81 BPR, klaster kedua terdiri dari 2 BPR, dan 1 BPR sisanya termasuk dalam klaster ketiga.

#### 4.6.2. BPRS

Berdasarkan jumlah klaster yang dihasilkan pada penelitian oleh Puspita dan Pratiwi (2016) serta Guna (2023) dan juga jumlah data BPRS yang berjumlah kurang dari 10, jumlah klaster yang digunakan untuk pengelompokan BPRS adalah 2 dan 3. Selanjutnya, analisis *clustering* dengan algoritma *fuzzy c-means* dilakukan dengan tahapan sebagai berikut,

- Menginisiasi parameter awal yang terdiri atas: indeks iterasi awal  $\eta = 1$ ; jumlah iterasi maksimum  $\eta_{max} = 100$ ; *fuzziness*  $m = 2$ ; dan nilai konvergensi  $\varepsilon = 10^{-5}$  (Borlea dkk., 2021; Yohannes, 2016).
- Menginisiasi matriks *centroid* awal secara acak sesuai persamaan (2.19). Ukuran matriks *centroid* disesuaikan dengan jumlah variabel yang dimiliki dan jumlah klaster yang ingin dibentuk. Sebagai contoh dalam pengelompokan BPRS menjadi 2 klaster, matriks *centroid*

memiliki ukuran  $[4 \times 2]$  seperti berikut,

$$\mathbf{C}^{(1)} = \begin{bmatrix} 4,53 & 8,83 \\ 135,10 & 316,67 \\ 14,05 & 10,34 \\ 63,08 & 54,46 \end{bmatrix}$$

- c. Menghitung jarak  $d_{c_j, x_i}$  untuk tiap kombinasi objek  $x_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan (2.20)  
Sebagai contoh untuk data BPRS ke-1 yakni,

$$x_1 = [10,50 \quad 88,99 \quad 9,14 \quad 23,33]$$

Jarak  $c_1$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$\begin{aligned} d_{c_1, x_1} &= \sqrt{(10,50 - 4,53)^2 + (88,99 - 135,10)^2 + (9,14 - 14,05)^2 + (23,33 - 63,08)^2} \\ &= 61,37 \end{aligned}$$

Jarak  $c_2$  terhadap  $x_1$  dihitung dengan rumus sebagai berikut,

$$\begin{aligned} d_{c_2, x_1} &= \sqrt{(10,50 - 8,83)^2 + (88,99 - 316,67)^2 + (9,14 - 10,34)^2 + (23,33 - 54,46)^2} \\ &= 229,81 \end{aligned}$$

Setelah menghitung seluruh jarak  $d_{c_j, x_i}$  untuk tiap kombinasi objek dan *centroid*, diperoleh matriks jarak berukuran  $[7 \times 2]$  sebagai berikut

$$\mathbf{D}^{(1)} = \begin{bmatrix} 61,37 & 229,81 \\ \vdots & \vdots \\ 181,86 & 0,00 \\ 20,35 & 196,14 \end{bmatrix}$$

- d. Membentuk matriks keanggotaan  $\mu_c^{(\eta)}$  seperti pada persamaan (2.31). Matriks tersebut terdiri atas elemen-elemen  $\mu_{c_j}^{(\eta)}(x_i)$  yang mewakili derajat keanggotaan sebuah objek  $x_i$  ke dalam kluster  $c_j$  yang dihitung dengan persamaan (2.29).  
Sebagai contoh untuk data BPRS ke-1,  $\mu_{c_j}^{(\eta)}(x_1)$  untuk tiap kluster adalah sebagai berikut,

$$\mu_{c_1}^{(1)}(x_1) = \frac{\left(\frac{1}{d_{c_1, x_1}}\right)^{\frac{2}{2-1}}}{\left(\frac{1}{d_{c_1, x_1}}\right)^{\frac{2}{2-1}} + \left(\frac{1}{d_{c_2, x_1}}\right)^{\frac{2}{2-1}}} = \frac{\left(\frac{1}{61,37}\right)^2}{\left(\frac{1}{61,37}\right)^2 + \left(\frac{1}{229,81}\right)^2}$$

$$\mu_{c_1}^{(1)}(x_1) = \frac{0,00027}{(0,00027) + (1,89 \times 10^{-5})} = 0,9344$$

$$\mu_{c_2}^{(1)}(x_1) = \frac{(1,89 \times 10^{-5})}{(0,00027) + (1,89 \times 10^{-5})} = 0,0666$$

Setelah menghitung seluruh jarak  $\mu_{c_j}^{(\eta)}(x_i)$  untuk tiap kombinasi objek dan kluster, diperoleh matriks keanggotaan  $\mu_c^{(\eta)}$  pada iterasi pertama dengan ukuran  $[7 \times 2]$  sebagai berikut

$$\mu_c^{(1)} = \begin{bmatrix} 0,9344 & 0,0666 \\ \vdots & \vdots \\ 3,0 \times 10^{-5} & 0,9999 \\ 0,9893 & 0,0106 \end{bmatrix}$$

- e. Menghitung *centroid* baru untuk setiap kluster yakni  $c_j^{(\eta+1)}$  berdasarkan persamaan (2.32). Sebagai contoh, kluster 1 yang terdiri atas 6 objek data, *centroid* baru untuk variabel NPL dihitung dengan rumus sebagai berikut

$$\begin{aligned} c_{1_1}^{(2)} &= \frac{\sum_{i=1}^n \{[\mu_{c_j}^{(\eta)}(x_i)]^m x_{i_1}\}}{\sum_{i=1}^n [\mu_{c_j}^{(\eta)}(x_i)]^m} \\ &= \frac{\{0,9344^2 \times 10,50\} + \dots + \{0,9893^2 \times 17,20\}}{(0,9344^2 + \dots + 0,9893^2)} = \frac{9,15 + \dots + 16,84}{0,87 + \dots + 0,98} = 15,69 \end{aligned}$$

Setelah perhitungan seluruh *centroid* baru untuk tiap variabel dan tiap kluster, diperoleh matriks *centroid* baru sebagai berikut,

$$C^{(2)} = \begin{bmatrix} 15,69 & 9,07 \\ 112,41 & 313,31 \\ 9,27 & 10,30 \\ 37,90 & 54,01 \end{bmatrix}$$

- f. Membentuk matriks keanggotaan baru untuk iterasi selanjutnya  $\mu_c^{(\eta+1)}$  seperti yang dilakukan pada langkah ke-d. Matriks keanggotaan baru  $\mu_c^{(\eta)}$  pada iterasi kedua berukuran  $[7 \times 2]$  adalah sebagai berikut

$$\mu_c^{(2)} = \begin{bmatrix} 0,9853 & 0,0147 \\ \vdots & \vdots \\ 2,4 \times 10^{-5} & 0,9999 \\ 0,9891 & 0,0109 \end{bmatrix}$$

- g. Mengecek kriteria pemberhentian algoritma yakni persamaan (2.33) dan kemudian (2.27). Jika memenuhi, hasil kluster sesuai dengan persamaan (2.34). Jika tidak,  $\eta$  ditambah secara bertahap dan tahapan diulang dari langkah ke-e.

Berdasarkan kriteria pemberhentian persamaan (2.33),  $|\mu_c^{(2)} - \mu_c^{(1)}| < \varepsilon$  tidak terpenuhi atau matriks keanggotaan masih berubah setelah dua iterasi berturut-turut. Oleh karena itu, tahapan *clustering* diulang kembali dari langkah ke-e sampai menemukan hasil klusterisasi yang optimal dan memenuhi kriteria pemberhentian algoritma.

Setelah mendapatkan hasil klusterisasi untuk setiap jumlah kluster, hasil klusterisasi dievaluasi menggunakan nilai validitas *cluster* indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz*.

## 1. Indeks *Silhouette*

Evaluasi hasil pengelompokan BPRS dengan indeks *Silhouette* diperoleh dengan mendapatkan nilai indeks *Silhouette* per objek data terlebih dahulu. Kemudian nilai indeks *Silhouette* seluruh objek dalam *dataset* dihitung rata-ratanya agar didapatkan nilai indeks *Silhouette* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Silhouette fuzzy* hasil klusterisasi algoritma *fuzzy c-means* 2 kluster dari data BPRS tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Untuk data BPRS ke-1 ( $x_1$ ) yang dikelompokkan ke kluster 1 beranggotakan 6 BPRS, dihitung rerata ketidaksamaan ( $a_1$ ) yakni rata-rata jarak  $x_1$  terhadap  $x_i$  lain pada kluster 1.

$$\begin{aligned}
a_1 &= \frac{\sum_{j=1}^{n_1} (\mu_{c_1}(x_j))^m \times \|x_1 - x_j\|}{\sum_{j=1}^{n_1} (\mu_{c_1}(x_j))^m}, j \neq 1 \\
&= \frac{\left\{ (\mu_{c_1}(x_2))^2 \times \|x_1 - x_2\| \right\} + \dots + \left\{ (\mu_{c_1}(x_6))^2 \times \|x_1 - x_6\| \right\}}{(\mu_{c_1}(x_1))^2 + \dots + (\mu_{c_1}(x_6))^2} \\
&= \frac{\{0,9803 \times 23,26\} + \dots + \{0,9750 \times 46,43\}}{0,9803 + \dots + 0,9750} = 39,56
\end{aligned}$$

- b. Selanjutnya, menghitung rerata ketidaksamaan  $d(1, C)$  antara  $x_1$  pada kluster 1 terhadap semua  $x_i$  di kluster C yang mana C adalah semua kluster selain kluster 1. Nilai  $d(1, C_2)$  dimana kluster 2 terdiri atas 1 anggota adalah,

$$\begin{aligned}
d(1, C_2) &= \frac{\sum_{j=1}^{n_2} (\mu_{c_2}(x_{jC_2}))^m \times \|x_{1C_1} - x_{jC_2}\|}{\sum_{j=1}^{n_2} (\mu_{c_2}(x_{jC_2}))^m} = \frac{\left\{ (\mu_{c_2}(x_{1C_2}))^2 \times \|x_{1C_1} - x_{1C_2}\| \right\}}{(\mu_{c_2}(x_{1C_2}))^2} \\
&= \frac{0,9999 \times 229,80}{0,9999} = 229,80
\end{aligned}$$

- c. Setelah menghitung  $d(1, C)$  untuk semua kluster selain kluster 1, dipilih nilai minimum dari  $d(1, C)$  yang akan disebut sebagai  $b_1$ .

$$b_1 = \min(d(1, C_2)) = 229,80$$

- d. Kemudian nilai indeks *silhouette* untuk data BPRS ke-1 ( $x_1$ ) dihitung dengan persamaan (2.39) sebagai berikut,

$$Sil_1 = \frac{(b_1 - a_1)}{\max(a_1, b_1)} = \frac{(229,80 - 39,56)}{\max(229,8 ; 39,56)} = 0,8279$$

- e. Terakhir nilai indeks *silhouette* hasil klusterisasi algoritma *fuzzy c-means* 2 kluster diperoleh dengan menghitung rata-rata  $Sil_i$  semua objek data.

$$Sil = \frac{1}{n} \sum_{i=1}^n Sil_i = \frac{1}{7} (0,8279 + \dots + 0,8121) = 0,8168$$

## 2. Indeks *Davies-Bouldin*

Evaluasi hasil pengelompokan BPRS dengan indeks *Davies-Bouldin* diperoleh dengan mendapatkan perhitungan rata-rata jarak setiap objek data terhadap pusat kluster dan jarak antar pusat kluster terlebih dahulu. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Davies-Bouldin* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Davies-Bouldin* hasil klusterisasi algoritma *fuzzy c-means* 2 kluster dari data BPRS tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung nilai rata-rata jarak tiap objek data terhadap pusat klusternya ( $S_i$ ) untuk setiap kluster dengan persamaan (2.42)

$$S_1 = \frac{1}{n_1} \sum_{j=1}^{n_1} \|x_j - c_1\| = \frac{1}{6} (26,68 + 20,96 + \dots + 22,08) = 25,61$$

$$S_2 = \frac{1}{n_2} \sum_{j=1}^{n_2} \|x_j - c_2\| = \frac{1}{1} (0,51) = 0,51$$

- b. Menghitung jarak separasi antar kluster ( $M_{ij}$ ) untuk setiap pasangan *centroid* saat  $i \neq j$  sesuai persamaan (2.43)

$$M_{1,2} = \|c_1 - c_2\| = \sqrt{(16,19 - 8,84)^2 + \dots + (36,70 - 54,45)^2} = 205,70$$

- c. Menghitung nilai  $R_{ij}$  untuk setiap pasangan *centroid* saat  $i \neq j$  dengan persamaan (2.41)

$$R_{1,2} = \frac{S_1 + S_2}{M_{1,2}} = \frac{25,61 + 0,51}{205,70} = 0,1270$$

- d. Menghitung nilai indeks *Davies-Bouldin* hasil klusterisasi menggunakan persamaan (2.40)

$$DB = 0,1270$$

### 3. Indeks *Calinski-Harabasz*

Evaluasi hasil pengelompokan BPRS dengan indeks *Calinski-Harabasz* diperoleh dengan menghitung terlebih dahulu *sum of squares within cluster* atau jarak setiap objek data terhadap pusat kluster dan *sum of squares between cluster* atau jarak antar pusat kluster. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Calinski-Harabasz* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Calinski-Harabasz* hasil klusterisasi algoritma *fuzzy c-means* 2 kluster dari data BPRS tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung *sum of squares within cluster* atau *SSW* sesuai persamaan (2.45)

$$SSW = \sum_{i=1}^k \sum_{j=1}^{n_k} \|x_{jk} - c_k\|^2 = \sum_{i=1}^k \left( \sum_{j=1}^{n_1} \|x_{j1} - c_1\|^2 + \sum_{j=1}^{n_2} \|x_{j2} - c_2\|^2 \right)$$

$$SSW = ((711,92 + \dots + 487,71) + (0,26)) = (4410,45 + 0,26) = 4410,71$$

- b. Menghitung *sum of squares between cluster* atau *SSB* sesuai persamaan (2.46)

$$SSB = \sum_{i=1}^k n_k \times \|c_k - c\|^2 = (n_1 \times \|c_1 - c\|^2) + (n_2 \times \|c_2 - c\|^2)$$

$$SSB = (6 \times 31005,3) + (1 \times 5261,67) = 36266,99$$

4. Menghitung nilai indeks *Calinski-Harabasz* hasil klusterisasi sesuai persamaan (2.44)

$$CH = \frac{SSB}{SSW} \times \frac{(n - k)}{(k - 1)} = \frac{36266,99}{4410,71} \times \frac{(7 - 2)}{(2 - 1)} = 41,11$$

Evaluasi hasil *clustering* algoritma *fuzzy c-means* dalam pengelompokan BPRS menggunakan indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz* secara lengkap disajikan pada Tabel 4.22.

**Tabel 4.22** Evaluasi Hasil Klusterisasi BPRS dengan Algoritma *Fuzzy C-means*

Bank	z-score	Jumlah Kluster	Nilai Validasi		
			Sil	DB	CH
BPRS	Tanpa	2	0,8168	0,1270	41,1124
		3	0,5098	0,5822	42,1826
	Dengan	2	0,5438	0,9535	4,8282
		3	0,4491	0,6679	4,3206

Kemudian dilakukan pemilihan hasil klasterisasi BPRS terbaik berdasarkan nilai validasi *Sil* paling mendekati 1 (Zhao, dkk., 2023), *DB* terkecil (Davies dan Bouldin, 1979), dan *CH* terbesar (Ros, dkk., 2023). Berdasarkan Tabel 4.23, analisis *clustering* BPRS dengan algoritma *fuzzy c-means* menghasilkan pengelompokan terbaik saat klaster berjumlah 2 kelompok dengan data tanpa proses standarisasi. *Centroid* atau pusat klaster dari hasil klasterisasi terbaik tersebut disajikan pada Tabel 4.23.

**Tabel 4.23** Pusat Kluster BPRS Terbaik dengan *Fuzzy C-means*

Kluster	Variabel				Jumlah Anggota Kluster
	NPL	LDR	NI	KPMM	
1	16,19	111,37	9,10	36,70	6
2	8,84	316,16	10,34	54,45	1

Berdasarkan nilai *centroid* pada Tabel 4.23, kemudian dihitung  $\mu_{c_j}^{(\eta)}(x_i)$  atau derajat keanggotaan setiap kombinasi data  $x_i, i = 1, \dots, n$  dan *centroid*  $c_j, j = 1, \dots, k$  menggunakan persamaan (2.29). Secara lebih lengkap, derajat keanggotaan tiap data BPRS terhadap seluruh *centroid* yang terbentuk disajikan pada Tabel 4.24.

**Tabel 4.24** Derajat Keanggotaan Hasil Klasterisasi BPRS Terbaik dengan *Fuzzy C-means*

Nama BPRS	$\mu_{c_1}(x_n)$	$\mu_{c_2}(x_n)$
PT BPRS Amanah Sejahtera	0,9866	0,0134
PT BPRS Mandiri Mitra Sukses	0,9901	0,0099
PT BPRS Karya Mugi Sentosa	0,9932	0,0068
PT BPRS Baktimakmur Indah	0,9789	0,0211
PT BPRS Annisa Mukti	0,9586	0,0414
PT BPRS Unawi Barokah	$6,1 \times 10^{-6}$	0,9999
PT BPRS Madinah	0,9874	0,0126

Derajat keanggotaan pada Tabel 4.25 dapat diartikan sebagai kecenderungan suatu objek data dikelompokkan ke dalam suatu klaster tertentu. Sebagai contoh, PT BPRS Amanah Sejahtera berpeluang sebesar 0,9866 masuk ke klaster 1 dan berpeluang masuk ke klaster 2 hanya sebesar 0,0134. Oleh karenanya, data pertama secara *hard clustering* dapat dikelompokkan ke dalam klaster 1. Sebaliknya, PT BPRS Unawi Barokah dapat dikelompokkan ke klaster 2 karena memiliki derajat keanggotaan terhadap klaster 2 sebesar 0,9999 yang mana nilainya lebih besar jika dibandingkan dengan derajat keanggotaan terhadap klaster 1. Hasil klasterisasi BPRS secara lengkap dapat dilihat pada Tabel 4.25. Pada pengelompokan 2 klaster dari data tanpa standarisasi menggunakan algoritma *fuzzy c-means*, klaster pertama terisi 6 BPRS sedangkan klaster kedua hanya beranggotakan 1 BPRS.

**Tabel 4.25** Hasil Klasterisasi BPRS Terbaik dengan *Fuzzy C-Means*

Kluster	Anggota Kluster	
	Nama Kabupaten/Kota	Nama Bank Pembiayaan Rakyat Syariah
1 (6 anggota)	Kabupaten Gresik	PT BPRS Amanah Sejahtera, PT BPRS Mandiri Mitra Sukses
	Kota Surabaya	PT BPRS Karya Mugi Sentosa
	Kabupaten Sidoarjo	PT BPRS Baktimakmur Indah, PT BPRS Annisa Mukti
	Kabupaten Lamongan	PT BPRS Madinah
2 (1 anggota)	Kabupaten Sidoarjo	PT BPRS Unawi Barokah

#### 4.7. Klasterisasi Menggunakan Algoritma *Self-Organizing Map* (SOM)

Dalam melakukan analisis *clustering* termasuk dengan algoritma SOM, digunakan data tanpa standarisasi dan data yang telah distandarisasi. Kemudian sebelum melakukan klasterisasi, harus ditentukan terlebih dahulu jumlah klaster yang mewakili banyaknya kelompok yang akan terbentuk. Setelah melakukan analisis *clustering* sesuai dengan jumlah klaster yang ditentukan, setiap hasil klasterisasi akan dievaluasi menggunakan nilai indeks validitas *cluster Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz*. Terakhir, dilakukan pemilihan hasil klasterisasi terbaik untuk tiap jenis perbankan berdasarkan ketiga nilai indeks validitas *cluster*.

##### 4.7.1. BPR

Berdasarkan jumlah klaster yang dihasilkan pada penelitian oleh Puspita dan Pratiwi (2016), Pristyandini (2018), dan juga Guna (2023) serta jumlah peringkat pada Peraturan OJK No.3 Tahun 2022 tentang Penilaian Tingkat Kesehatan BPR dan BPRS, jumlah klaster yang digunakan untuk pengelompokan BPR adalah 3, 4, dan 5. Selanjutnya, analisis *clustering* dengan algoritma SOM dilakukan dengan tahapan sebagai berikut,

- Menentukan *grid output neuron* SOM sesuai dengan jumlah klaster yang akan dibentuk. Sebagai contoh, untuk pengelompokan 3 klaster, *grid output neuron* SOM dibentuk dari dimensi  $u_x = 1$  dan dimensi  $u_y = 3$  sehingga *output neuron* SOM berjumlah 3.
- Membangun model SOM dengan parameter yang terdiri atas: *learning iteration number* ( $t = 0$ ), jumlah iterasi ( $T = 200$ ), *learning rate* ( $\alpha = 0,9$ ), serta *neighbourhood radius* ( $radius = 0,5$ ) (Bigdeli dkk., 2022).
- Menginisiasi matriks bobot yang berkaitan dengan *output neuron* dengan nilai yang acak. Ukuran matriks disesuaikan dengan jumlah klaster yang ingin dibentuk dan jumlah variabel yang dimiliki. Sebagai contoh dalam pengelompokan BPR menjadi 3 klaster, matriks bobot memiliki ukuran  $[3 \times 6]$  seperti berikut,

$$\mathbf{w} = \begin{bmatrix} 17,91 & 175,61 & 104,20 & 3,37 & 15,43 & 123,28 \\ 8,95 & 113,60 & 89,65 & 1,54 & 11,59 & 65,29 \\ 3,40 & 74,31 & 77,25 & 0,00 & 8,17 & 35,36 \end{bmatrix}$$

- Memilih vektor *input*  $\mathbf{x}_i$  secara acak dan kemudian menghitung jarak *Euclidean* antara vektor *input* tersebut terhadap seluruh *output neuron*.

Misalkan dipilih data BPR ke-1 sebagai vektor *input*  $\mathbf{x}_i$  yang dinyatakan sebagai berikut,

$$\mathbf{x}_i = [14,60 \quad 371,26 \quad 66,53 \quad 9,08 \quad 23,07 \quad 120,89]$$

Jarak *Euclidean* antara  $\mathbf{x}_i$  terhadap *output neuron* ke-1 yang diwakili vektor bobot  $\mathbf{w}_1$  dihitung pada rumus sebagai berikut

$$\begin{aligned} d_{\mathbf{w}_1, \mathbf{x}_i} &= \sqrt{(14,60 - 17,91)^2 + (371,26 - 175,61)^2 + (66,53 - 104,20)^2 +} \\ &= \sqrt{(9,08 - 3,37)^2 + (23,07 - 15,43)^2 + (120,89 - 123,28)^2} = 199,51 \end{aligned}$$

Jarak *Euclidean* terhadap *output neuron* ke-2 yang diwakili vektor bobot  $\mathbf{w}_2$  dihitung dengan rumus sebagai berikut,

$$\begin{aligned} d_{\mathbf{w}_2, \mathbf{x}_i} &= \sqrt{(14,60 - 8,95)^2 + (371,26 - 113,60)^2 + (66,53 - 89,65)^2 +} \\ &= \sqrt{(9,08 - 1,54)^2 + (23,07 - 11,59)^2 + (120,89 - 65,29)^2} = 265,02 \end{aligned}$$

Jarak *Euclidean* terhadap *output neuron* ke-3 yang diwakili vektor bobot  $\mathbf{w}_3$  dihitung dengan

rumus sebagai berikut,

$$d_{w_2, x_i} = \sqrt{(14,60 - 3,4)^2 + (371,26 - 74,31)^2 + (66,53 - 77,25)^2 + (9,08 - 0,00)^2 + (23,07 - 8,17)^2 + (120,89 - 35,36)^2} = 309,90$$

- e. Memilih *output neuron* yang vektor bobotnya menghasilkan jarak paling minimum dengan vektor *input* sebagaimana persamaan (2.35). *Output neuron* yang terpilih disebut sebagai *winning neuron* dan selanjutnya diberi indeks  $g$ .

Pada data BPR ke-1 sebagai vektor *input*  $x_i$ , *output neuron* yang vektor bobotnya menghasilkan jarak paling minimum dengan vektor *input* adalah *output neuron* ke-1 dengan jarak sebesar 199,51. Sehingga, *output neuron* ke-1 terpilih menjadi *winning neuron*.

- f. Memperbarui vektor bobot *winning neuron*  $w_g$  dengan persamaan (2.36). Sedangkan vektor bobot *output neuron* lainnya diperbarui juga menggunakan persamaan (2.37).

Sebagai contoh, pembaharuan vektor bobot *winning neuron*  $w_g$  pada variabel NPL adalah sebagai berikut,

$$w_1(t+1) = w_1(t) + 0,9(x_{i_1} - w_1(t)) = 17,91 + 0,9(14,60 - 17,91) = 14,93$$

Sedangkan pembaharuan vektor bobot *output neuron* ke-2 ( $w_2$ ) dan ke-3 ( $w_3$ ) pada variabel NPL adalah sebagai berikut,

$$w_{2_1}(t+1) = w_{2_1}(t) + h_{1,2}(t)(x_{i_1} - w_{2_1}(t)) = 8,95 + 0,00(14,60 - 8,95) = 8,95$$

$$w_{3_1}(t+1) = w_{3_1}(t) + h_{1,3}(t)(x_{i_1} - w_{3_1}(t)) = 3,40 + 0,00(14,60 - 3,40) = 3,40$$

- g. Mengecek kriteria pemberhentian algoritma, jika  $t < T$ , kembali ke langkah d dan sebaliknya jika  $t > T$ , algoritma SOM sudah selesai.

Sebagai contoh apabila jumlah iterasi  $T$  sudah terpenuhi, akan didapatkan matriks bobot final sebagai berikut,

$$w^{(T)} = \begin{bmatrix} 4,44 & 1876,28 & 87,27 & 2,96 & 20,31 & 146,61 \\ 12,91 & 341,67 & 70,59 & 7,49 & 21,47 & 103,11 \\ 4,18 & 112,40 & 85,34 & 1,24 & 17,12 & 28,65 \end{bmatrix}$$

Setelah didapatkan matriks bobot final, dihitung jarak seluruh objek data terhadap setiap vektor bobot final. Sebagai contoh, jarak data BPR ke-1 terhadap vektor bobot *output neuron* ke-1 dihitung dengan rumus sebagai berikut,

$$d_{w_1, x_i} = \sqrt{(14,60 - 4,44)^2 + (371,26 - 1876,28)^2 + (66,53 - 87,27)^2 + (9,08 - 2,96)^2 + (23,07 - 20,31)^2 + (120,89 - 146,61)^2} = 1505,43$$

Setelah menghitung jarak seluruh objek data terhadap setiap vektor bobot final, diperoleh matriks jarak final berukuran  $[84 \times 3]$  sebagai berikut

$$D^{(T)} = \begin{bmatrix} 1505,43 & 34,87 & 275,82 \\ 588,91 & 2118,79 & 2353,52 \\ \vdots & \vdots & \vdots \\ 1752,56 & 217,95 & 67,09 \\ 1735,28 & 200,83 & 92,51 \end{bmatrix}$$

Matriks jarak final tersebut merupakan dasar dalam pengelompokan objek data ke suatu kluster. Sebagai contoh data BPR ke-1 akan dikelompokkan ke kluster 2 karena memiliki jarak sebesar 34,87 yang mana paling kecil dibanding jarak terhadap dua kluster lainnya.

Setelah mendapatkan hasil klusterisasi untuk setiap jumlah kluster, hasil klusterisasi dievaluasi menggunakan nilai validitas *cluster* indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz*.

### 1. Indeks *Silhouette*

Evaluasi hasil pengelompokan BPR dengan indeks *Silhouette* diperoleh dengan mendapatkan nilai indeks *Silhouette* per objek data terlebih dahulu. Kemudian nilai indeks *Silhouette* seluruh objek dalam *dataset* dihitung rata-ratanya agar didapatkan nilai indeks *Silhouette* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Silhouette* hasil klusterisasi algoritma SOM 3 kluster dari data BPR tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Untuk data BPR ke-1 ( $x_1$ ) yang dikelompokkan ke kluster 2 beranggotakan 13 BPR, dihitung rerata ketidaksamaan ( $a_1$ ) yakni rata-rata jarak  $x_1$  terhadap  $x_j$  lain pada kluster 2.

$$a_1 = \frac{\sum_{j=1}^{n_2} \|x_1 - x_j\|}{n_2 - 1}, j \neq 1$$

$$= \frac{\|x_1 - x_2\| + \dots + \|x_1 - x_{13}\|}{13 - 1} = \frac{174,44 + \dots + 114,25}{12} = 146,93$$

- b. Selanjutnya, menghitung rerata ketidaksamaan  $d(1, C)$  antara  $x_1$  pada kluster 2 terhadap semua  $x_i$  di kluster C yang mana C adalah semua kluster selain kluster 2. Nilai  $d(1, C_1)$  dimana kluster 1 terdiri atas 3 anggota adalah,

$$d(1, C_1) = \frac{\sum_{j=1}^{n_1} \|x_{1C_2} - x_{jC_1}\|}{n_1} = \frac{\|x_{1C_2} - x_{1C_1}\| + \dots + \|x_{1C_2} - x_{3C_1}\|}{3}$$

$$= \frac{2088,09 + 1907,51 + 3942,89}{3} = 2646,16$$

Sedangkan nilai  $d(1, C_3)$  dimana kluster 3 terdiri dari 68 BPR sebagai anggota adalah,

$$d(1, C_3) = \frac{\sum_{j=1}^{n_1} \|x_{1C_2} - x_{jC_3}\|}{n_1} = \frac{\|x_{1C_2} - x_{1C_3}\| + \dots + \|x_{1C_2} - x_{68C_3}\|}{68}$$

$$= \frac{273,29 + \dots + 230,26}{68} = 288,35$$

- c. Setelah menghitung  $d(1, C)$  untuk semua kluster selain kluster 2, dipilih nilai minimum dari  $d(1, C)$  yang akan disebut sebagai  $b_1$ .

$$b_1 = \min(d(1, C_1); d(1, C_3)) = \min(2646,16 ; 288,35) = 288,35$$

- d. Kemudian nilai indeks *Silhouette* untuk data BPR ke-1 ( $x_1$ ) dihitung dengan persamaan (2.39) sebagai berikut,

$$Sil_1 = \frac{(b_1 - a_1)}{\max(a_1, b_1)} = \frac{(288,35 - 146,93)}{\max(288,35 ; 146,93)} = 0,4904$$

- e. Terakhir nilai indeks *Silhouette* hasil klusterisasi algoritma SOM 3 kluster diperoleh dengan menghitung rata-rata  $Sil_i$  semua objek data.

$$Sil = \frac{1}{n} \sum_{i=1}^n Sil_i = \frac{1}{84} (0,4904 + \dots + 0,5121) = 0,5486$$

## 2. Indeks *Davies-Bouldin*

Evaluasi hasil pengelompokan BPR dengan indeks *Davies-Bouldin* diperoleh dengan mendapatkan perhitungan rata-rata jarak setiap objek data terhadap bobot *output neuron* tempat objek data berada dan jarak antar bobot *output neuron* terlebih dahulu. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Davies-Bouldin* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Davies-Bouldin* hasil klusterisasi algoritma SOM 3 kluster dari data BPR tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung nilai rata-rata jarak tiap objek data terhadap bobot *output neuron*-nya ( $S_i$ ) untuk setiap kluster dengan persamaan (2.42)

$$S_1 = \frac{1}{n_1} \sum_{j=1}^{n_1} \|x_j - w_1\| = \frac{1}{3} (562,07 + 738,65 + 1297,67) = 866,13$$

$$S_2 = \frac{1}{n_2} \sum_{j=1}^{n_2} \|x_j - w_2\| = \frac{1}{13} (46,35 + 131,78 + \dots + 78,96) = 194,20$$

$$S_3 = \frac{1}{n_3} \sum_{j=1}^{n_3} \|x_j - w_3\| = \frac{1}{68} (6,59 + 44,19 + \dots + 62,89) = 106,69$$

- b. Menghitung jarak separasi antar kluster ( $M_{ij}$ ) untuk setiap pasangan vektor bobot *output neuron* saat  $i \neq j$  sesuai persamaan (2.43)

$$M_{1,2} = \|w_1 - w_2\| = \sqrt{(1,94 - 15,62)^2 + \dots + (211,62 - 144,17)^2} = 2678,25$$

$$M_{1,3} = \|w_1 - w_3\| = \sqrt{(1,94 - 11,49)^2 + \dots + (211,62 - 76,57)^2} = 2918,84$$

$$M_{2,3} = \|w_2 - w_3\| = \sqrt{(15,62 - 11,49)^2 + \dots + (144,17 - 76,57)^2} = 248,05$$

- c. Menghitung nilai  $R_{ij}$  untuk setiap pasangan vektor bobot *output neuron* saat  $i \neq j$  dengan persamaan (2.41)

$$R_{1,2} = \frac{S_1 + S_2}{M_{1,2}} = \frac{866,13 + 194,20}{2678,25} = 0,3959$$

$$R_{1,3} = \frac{S_1 + S_3}{M_{1,3}} = \frac{866,13 + 106,69}{2918,84} = 0,3333$$

$$R_{2,3} = \frac{S_2 + S_3}{M_{2,3}} = \frac{194,20 + 106,69}{248,05} = 1,2310$$

- d. Menghitung nilai indeks *Davies-Bouldin* hasil klusterisasi menggunakan persamaan (2.40)

$$DB = \frac{1}{3} (0,3959 + 0,3333 + 1,2310) = 0,6474$$

## 3. Indeks *Calinski-Harabasz*

Evaluasi hasil pengelompokan BPR dengan indeks *Calinski-Harabasz* diperoleh dengan menghitung terlebih dahulu *sum of squares within cluster* atau jarak setiap objek data terhadap vektor bobot *output neuron*-nya dan *sum of squares between cluster* atau jarak antar vektor bobot *output neuron*. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Calinski-Harabasz* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Calinski-Harabasz* hasil

klasterisasi algoritma SOM 3 kluster dari data BPR tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

a. Menghitung *sum of squares within cluster* atau *SSW* sesuai persamaan (2.45)

$$SSW = \sum_{i=1}^k \sum_{j=1}^{n_k} \|x_{jk} - w_k\|^2 = \sum_{i=1}^k \left( \sum_{j=1}^{n_1} \|x_{j1} - w_1\|^2 + \sum_{j=1}^{n_2} \|x_{j2} - w_2\|^2 + \sum_{j=1}^{n_3} \|x_{j3} - w_3\|^2 \right)$$

$$= (368436,54 + 614080,37 + 1569067,59) +$$

$$(1268645,52 + \dots + 1415567,82) + (11502 + \dots + 25297,80)$$

$$SSW = 2551584,49 + 17839376,19 + 1424205,90 = 3649873,86$$

b. Menghitung *sum of squares between cluster* atau *SSB* sesuai persamaan (2.46)

$$SSB = \sum_{i=1}^k n_k \times \|w_k - c\|^2 = (n_1 \times \|w_1 - c\|^2) + (n_2 \times \|w_2 - c\|^2) + (n_3 \times \|w_3 - c\|^2)$$

$$= (3 \times 2822,29) + (13 \times 1584421,05) + (68 \times 59742,15) = 24668406,94$$

c. Menghitung nilai indeks *Calinski-Harabasz* hasil klasterisasi sesuai persamaan (2.44)

$$CH = \frac{SSB}{SSW} \times \frac{(n - k)}{(k - 1)} = \frac{24668406,94}{3649873,86} \times \frac{(84 - 3)}{(3 - 1)} = 273,73$$

Evaluasi hasil *clustering* algoritma SOM dalam pengelompokan BPR menggunakan indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz* secara lengkap disajikan pada Tabel 4.26.

**Tabel 4.26** Evaluasi Hasil Klasterisasi BPR dengan Algoritma SOM

Bank	z-score	Jumlah Kluster	Nilai Validasi		
			Sil	DB	CH
BPR	Tanpa	3	0,5486	0,6474	273,7274
		4	0,3183	1,2126	87,6721
		5	0,2164	0,9528	154,6464
	Dengan	3	0,2876	1,4407	8,8811
		4	0,1174	1,6418	10,0999
		5	0,0652	1,3036	11,2089

Kemudian dilakukan pemilihan hasil klasterisasi BPR terbaik berdasarkan nilai validasi *Sil* paling mendekati 1 (Zhao, dkk., 2023), *DB* terkecil (Davies dan Bouldin, 1979), dan *CH* terbesar (Ros, dkk., 2023). Berdasarkan Tabel 4.26, analisis *clustering* BPR dengan algoritma SOM menghasilkan pengelompokan terbaik saat kluster berjumlah 3 kelompok dengan data tanpa proses standarisasi. Bobot *output neuron* hasil klasterisasi SOM terbaik disajikan pada Tabel 4.27.

**Tabel 4.27** Bobot *Output Neuron* SOM Hasil Klasterisasi BPR Terbaik

w	Variabel					
	NPL	LDR	BOPO	ROA	NIM	KPMM
1	4,44	1876,28	87,27	2,96	20,31	146,61
2	12,91	341,67	70,59	7,49	21,47	103,11
3	4,18	112,4	85,34	1,24	17,12	28,65

Selanjutnya dilakukan perhitungan jarak tiap objek data terhadap seluruh vektor bobot *output neuron* yang dihasilkan seperti halnya pada Tabel 4.27. Hasil perhitungan jarak beberapa data

BPR terhadap seluruh vektor bobot yang terbentuk disajikan pada Tabel 4.28. Jarak tiap data BPR dan vektor bobot *output neuron* secara lengkap dilampirkan pada Lampiran 5.

**Tabel 4.28** Jarak Terhadap Bobot dari Hasil Klasterisasi BPR Terbaik dengan SOM

Nama BPR	$d_{w_1, x_n}$	$d_{w_2, x_n}$	$d_{w_3, x_n}$
PT BPR Balongpanggang Sentosa	1505,43	34,87	275,82
PT BPR Dana Rajabally	588,91	2118,79	2353,52
⋮	⋮	⋮	⋮
PT BPR Delta Lamongan	1752,56	217,95	67,09
PT BPR Mitra Dhnaceswara	1735,28	200,83	92,51

Jarak pada Tabel 4.28 merupakan bahan pertimbangan bagi algoritma SOM dalam mengkategorikan objek data ke suatu klaster. Sebagai contoh, PT BPR Balongpanggang Sentosa dikelompokkan ke klaster 2 karena memiliki jarak terhadap vektor bobot ke-2 paling minimum yakni 34,87. Sedangkan PT BPR Dana Rajabally dikelompokkan ke klaster 1 karena memiliki jarak terhadap vektor bobot ke-1 paling minimum yakni 588,91. Begitu juga untuk PT BPR Mitra Dhnaceswara dikelompokkan ke klaster 3 karena memiliki jarak terhadap vektor bobot ke-3 paling minimum yakni 67,09. Hasil klasterisasi BPR dengan algoritma SOM secara lengkap dapat dilihat pada Tabel 4.29. Selain itu, hasil klasterisasi secara visual terlampir pada Gambar 4.7.

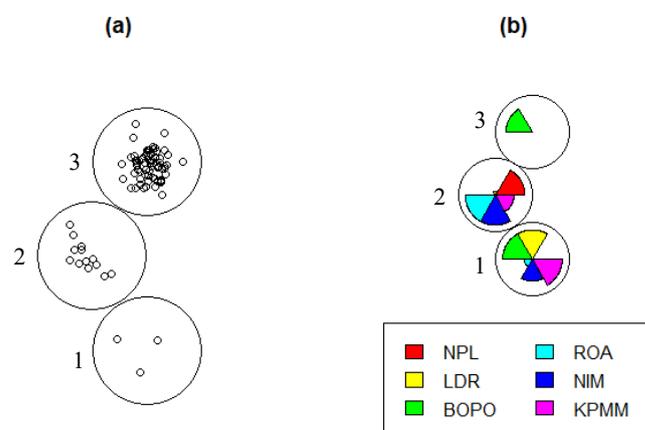
**Tabel 4.29** Hasil Klasterisasi BPR Terbaik dengan SOM

Klaster	Anggota Klaster	
	Nama Kabupaten/Kota	Nama Bank Perkreditan Rakyat
1 (3 anggota)	Kabupaten Gresik	PT BPR Dana Rajabally
	Kota Surabaya	PT BPR Rajadana Menganti, Permata Artha Surya
2 (13 anggota)	Kabupaten Gresik	BPR Balongpanggang Sentosa, BPR Bank Bumi Sanggabuana, BPR Kebomas, dan BPR Lestari Nusantara Indonesia
	Kabupaten Bangkalan	Perumda BPR Bangkalan
	Kabupaten Mojokerto	PT BPR Arta Haksaprima
	Kota Surabaya	PT BPR Bintang Mitra Indonesia
	Kabupaten Sidoarjo	PT BPR Bandataman, PT BPR Sarana Sukses, PT BPR Megakerta Swadiri, PT BPR Puridana Arthamas, PT BPR Artamulya Bumimukti, PT BPR Bumi Gora Jaya
3 (68 anggota)	Kabupaten Gresik	Perumda BPR Bank Gresik, BPR Intan Kita, BPR Aneka Dana Sejahtera, BPR Intan Nasional, BPR Mitra Cemawis Mandiri
	Kabupaten Bangkalan	PT BPR Dana Kerja Putra
	Kabupaten Mojokerto	PT BPR Arta Swasembada, KSP BPR Sendang Harta Sejahtera, PT BPR Bumi Jaya, PT BPR Mojosari Pahalpacto, PT BPR Karunia Berkat Intidana, PT BPR Arta Bangsal Utama, PT BPR Puriseger Sentosa
	Kota Mojokerto	PT BPR Majatama Perseroda, PT BPR Kurnia Dadi Arta
	Kota Surabaya	PT BPR Jawa Timur, PT BPR Danamitra Surya, PT BPR Kirana Indonesia, PT BPR Prima Kredit Utama,

Tabel 4.29 Hasil Klasterisasi BPR Terbaik dengan SOM (Lanjutan)

Klaster	Nama Kabupaten/Kota	Anggota Klaster
		Nama Bank Perkreditan Rakyat
		PT BPR Danamas, PT BPR Guna Yatra, PT BPR Kosanda, PT BPR Central Niaga, PT BPR Bina Kharisma Insani, PT BPR Surya Arthaguna Abadi, PT BPR Sili Corp Bank, PT BPR Karyaperdana Sejahtera, PT BPR Surya Artha Utama Perseroda, PT BPR Prima Master Bank
	Kabupaten Sidoarjo	PT BPR Krian Nusantara, PT BPR Sriekaya, PT BPR Artha Buana, PT BPR Bank Benta Tesa, PT BPR Taman Dhana, PT BPR Arta Waru Surya, PT BPR Satyadhana Artha, PT BPR Buana Dana Makmur, PT BPR Sinardana Buana, PT BPR Berkat Cahaya Artha, PT BPR Abrin Centra Artha, PT BPR Dinar Pusaka, PT BPR Bank Ima, PT BPR Gema Nusa, PT BPR Toelangan Dasa Nusantara, PT BPR Sari Dana Indonesia, PT BPR Taman Artha Kencana, PT BPR Padat Ganda, PT BPR Sahabat Mitra Artha, PT BPR Anglomas Indah, PT BPR Dana Raya Jawa Timur, PT BPR Dirgadhana Arthamas, PT BPR Mahkota Krian Wijaya, PT BPR Wutama Artha Sejahtera, PT BPR Sentra Dana Makmur, PT BPR Djojo Mandiri Raya, PT BPR Andalan Daerah, PT BPR Candisaka Arta, PT BPR Mitra Majujaya Mandiri, PT BPR Buduran Deltapurnam, PT BPR Delta Artha Perseroda, PT BPR Wiradhana Putramas, PT BPR Jati Lestari
	Kabupaten Lamongan	Perumda BPR Bank Daerah Lamongan, PT BPR Nusamba Brondong, PT BPR Rukun Karya Sari, PT BPR Ulintha Ganda, PT BPR Delta Lamongan, PT BPR Mitra Dhanaceswara

Pada klasterisasi BPR dengan algoritma SOM menjadi 3 klaster dari data tanpa proses standarisasi, klaster pertama beranggotakan 3 BPR, klaster kedua terdiri dari 13 BPR, dan 68 BPR sisanya termasuk dalam klaster ketiga.



Gambar 4.7 Plot Mapping (a) dan Codes (b) Hasil Klasterisasi BPR Terbaik

Pada plot codes hasil algoritma SOM, adanya diagram kipas menunjukkan variabel di klaster tersebut lebih dominan jika dibandingkan pada klaster lain. Berdasarkan Gambar 4.7 (b), klasterisasi BPR dengan algoritma SOM mengkategorikan BPR dengan variabel LDR, BOPO,

dan KPMM yang tinggi ke dalam kluster 1. Sedangkan BPR dengan variabel NPL, ROA, dan NIM yang tinggi dikelompokkan ke dalam kluster 2. Terakhir, BPR yang hanya memiliki nilai tinggi pada variabel BOPO dikategorikan ke dalam kluster 3.

#### 4.7.2. BPRS

Berdasarkan jumlah kluster yang dihasilkan pada penelitian oleh Puspita dan Pratiwi (2016) serta Guna (2023) dan juga jumlah data BPRS yang berjumlah kurang dari 10, jumlah kluster yang digunakan untuk pengelompokan BPRS adalah 2 dan 3. Selanjutnya, analisis *clustering* dengan algoritma SOM dilakukan dengan tahapan sebagai berikut,

- Menentukan *grid output neuron* SOM sesuai dengan jumlah kluster yang akan dibentuk. Sebagai contoh, untuk pengelompokan 2 kluster, *grid output neuron* SOM dibentuk dari dimensi  $u_x = 1$  dan dimensi  $u_y = 2$  sehingga *output neuron* SOM berjumlah 2.
- Membangun model SOM dengan parameter yang terdiri atas: *learning iteration number* ( $t = 0$ ), jumlah iterasi ( $T = 200$ ), *learning rate* ( $\alpha = 0,9$ ), serta *neighbourhood radius* ( $radius = 0,5$ ) (Bigdeli dkk., 2022).
- Menginisiasi matriks bobot yang berkaitan dengan *output neuron* dengan nilai yang acak. Ukuran matriks disesuaikan dengan jumlah kluster yang ingin dibentuk dan jumlah variabel yang dimiliki. Sebagai contoh dalam pengelompokan BPRS menjadi 2 kluster, matriks bobot memiliki ukuran  $[2 \times 4]$  seperti berikut,

$$\mathbf{w} = \begin{bmatrix} 16,91 & 127,92 & 11,43 & 55,42 \\ 6,68 & 102,31 & 8,06 & 27,11 \end{bmatrix}$$

- Memilih vektor *input*  $\mathbf{x}_i$  secara acak dan kemudian menghitung jarak *Euclidean* antara vektor *input* tersebut terhadap seluruh *output neuron*. Misalkan dipilih data BPRS ke-1 sebagai vektor *input*  $\mathbf{x}_i$  yang dinyatakan sebagai berikut,

$$\mathbf{x}_i = [10,50 \quad 88,99 \quad 9,14 \quad 23,33]$$

Jarak *Euclidean* antara  $\mathbf{x}_i$  terhadap *output neuron* ke-1 yang diwakili vektor bobot  $\mathbf{w}_1$  dihitung pada rumus sebagai berikut

$$\begin{aligned} d_{\mathbf{w}_1, \mathbf{x}_i} &= \sqrt{(10,50 - 16,91)^2 + (88,99 - 127,92)^2 + (9,14 - 11,43)^2 + (23,33 - 55,42)^2} \\ &= 50,91 \end{aligned}$$

Sedangkan jarak terhadap *output neuron* ke-2 yang diwakili vektor bobot  $\mathbf{w}_2$  dihitung dengan rumus sebagai berikut,

$$\begin{aligned} d_{\mathbf{w}_2, \mathbf{x}_i} &= \sqrt{(10,50 - 6,68)^2 + (88,99 - 102,31)^2 + (9,14 - 8,06)^2 + (23,33 - 27,11)^2} \\ &= 14,04 \end{aligned}$$

- Memilih *output neuron* yang vektor bobotnya menghasilkan jarak paling minimum dengan vektor *input* sebagaimana persamaan (2.35). *Output neuron* yang terpilih disebut sebagai *winning neuron* dan selanjutnya diberi indeks  $g$ .

Pada data BPRS ke-1 sebagai vektor *input*  $\mathbf{x}_i$ , *output neuron* yang vektor bobotnya menghasilkan jarak paling minimum dengan vektor *input* adalah *output neuron* ke-2 dengan jarak sebesar 14,04. Jarak tersebut lebih kecil dibandingkan terhadap *output neuron* ke-1. Sehingga, *output neuron* ke-2 terpilih menjadi *winning neuron*.

- Memperbarui vektor bobot *winning neuron*  $\mathbf{w}_g$  dengan persamaan (2.36). Sedangkan vektor bobot *output neuron* lainnya diperbarui juga menggunakan persamaan (2.37).

Sebagai contoh pembaharuan vektor bobot *winning neuron*  $w_g$  pada variabel NPL adalah sebagai berikut,

$$w_{2_1}(t+1) = w_{2_1}(t) + 0,9(x_{i_1} - w_{2_1}(t)) = 6,68 + 0,9(10,5 - 6,68) = 10,12$$

Sedangkan pembaharuan vektor bobot *output neuron* ke-1 ( $w_1$ ) pada variabel NPL adalah sebagai berikut,

$$w_{1_1}(t+1) = w_{1_1}(t) + h_{2,1}(t)(x_{i_1} - w_{1_1}(t)) = 16,91 + 0,00(10,5 - 16,91) = 16,91$$

- g. Mengecek kriteria pemberhentian algoritma, jika  $t < T$ , kembali ke langkah d dan sebaliknya jika  $t > T$ , algoritma SOM sudah selesai.

Sebagai contoh apabila jumlah iterasi  $T$  sudah terpenuhi, akan didapatkan matriks bobot final sebagai berikut,

$$w^{(T)} = \begin{bmatrix} 10,37 & 225,05 & 9,35 & 44,23 \\ 5,38 & 118,57 & 3,67 & 30,75 \end{bmatrix}$$

Setelah didapatkan matriks bobot final, dihitung jarak seluruh objek data terhadap setiap vektor bobot final. Sebagai contoh, jarak data BPRS ke-1 terhadap vektor bobot *output neuron* ke-1 dihitung dengan rumus sebagai berikut,

$$d_{w_1, x_i} = \sqrt{(10,50 - 10,37)^2 + (88,99 - 225,05)^2 + (9,14 - 9,35)^2 + (23,33 - 44,23)^2} \\ = 137,66$$

Setelah menghitung jarak seluruh objek data terhadap setiap vektor bobot final, diperoleh matriks jarak final berukuran  $[7 \times 2]$  sebagai berikut

$$D^{(T)} = \begin{bmatrix} 137,66 & 31,40 \\ \vdots & \vdots \\ 92,21 & 199,65 \\ 105,30 & 29,67 \end{bmatrix}$$

Matriks jarak final tersebut merupakan dasar dalam pengelompokan objek data ke suatu kluster. Sebagai contoh data BPRS ke-1 akan dikelompokkan ke kluster 2 karena memiliki jarak sebesar 31,40 yang mana lebih kecil dibanding jarak terhadap kluster 1 yang sebesar 137,66.

Setelah mendapatkan hasil klasterisasi untuk setiap jumlah kluster, hasil klasterisasi dievaluasi menggunakan nilai validitas *cluster* indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz*.

### 1. Indeks *Silhouette*

Evaluasi hasil pengelompokan BPRS dengan indeks *Silhouette* diperoleh dengan mendapatkan nilai indeks *Silhouette* per objek data terlebih dahulu. Kemudian nilai indeks *Silhouette* seluruh objek dalam *dataset* dihitung rata-ratanya agar didapatkan nilai indeks *Silhouette* hasil klasterisasi. Sebagai contoh, perhitungan nilai indeks *Silhouette* hasil klasterisasi algoritma SOM 2 kluster dari data BPRS tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Untuk data BPRS ke-1 ( $x_1$ ) yang dikelompokkan ke kluster 2 beranggotakan 6 BPRS, dihitung rerata ketidaksamaan ( $a_1$ ) yakni rata-rata jarak  $x_1$  terhadap  $x_j$  lain pada kluster 2.

$$a_1 = \frac{\sum_{j=1}^{n_2} \|x_1 - x_j\|}{n_2 - 1}, j \neq 1$$

$$= \frac{\|x_1 - x_2\| + \dots + \|x_1 - x_6\|}{6 - 1} = \frac{23,26 + \dots + 46,43}{5} = 39,82$$

- b. Selanjutnya, menghitung rerata ketidaksamaan  $d(1, C)$  antara  $x_1$  pada kluster 2 terhadap semua  $x_i$  di kluster C yang mana C adalah semua kluster selain kluster 2. Nilai  $d(1, C_1)$  dimana kluster 1 terdiri atas 1 anggota adalah,

$$d(1, C_1) = \frac{\sum_{j=1}^{n_1} \|x_{1C_2} - x_{jC_2}\|}{n_1} = \frac{\|x_{1C_2} - x_{1C_1}\|}{1} = 229,81$$

- c. Setelah menghitung  $d(1, C)$  untuk semua kluster selain kluster 2, dipilih nilai minimum dari  $d(1, C)$  yang akan disebut sebagai  $b_1$ .

$$b_1 = \min(d(1, C_1)) = 229,81$$

- d. Kemudian nilai indeks *Silhouette* untuk data BPRS ke-1 ( $x_1$ ) dihitung dengan persamaan (2.39) sebagai berikut,

$$Sil_1 = \frac{(b_1 - a_1)}{\max(a_1, b_1)} = \frac{(229,81 - 39,82)}{\max(229,81 ; 39,82)} = 0,8267$$

- e. Terakhir nilai indeks *Silhouette* hasil klusterisasi algoritma SOM 2 kluster diperoleh dengan menghitung rata-rata  $Sil_i$  semua objek data.

$$Sil = \frac{1}{n} \sum_{i=1}^n Sil_i = \frac{1}{7} (0,8267 + \dots + 0,8128) = 0,6907$$

## 2. Indeks *Davies-Bouldin*

Evaluasi hasil pengelompokan BPRS dengan indeks *Davies-Bouldin* diperoleh dengan mendapatkan perhitungan rata-rata jarak setiap objek data terhadap vektor bobot *output neuron*-nya dan jarak antar vektor bobot *output neuron* terlebih dahulu. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Davies-Bouldin* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Davies-Bouldin* hasil klusterisasi algoritma SOM 2 kluster dari data BPRS tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung nilai rata-rata jarak tiap objek data terhadap vektor bobot *output neuron*-nya ( $S_i$ ) untuk setiap kluster dengan persamaan (2.42)

$$S_1 = \frac{1}{n_1} \sum_{j=1}^{n_1} \|x_j - w_1\| = \frac{1}{1} (0,00) = 0,00$$

$$S_2 = \frac{1}{n_2} \sum_{j=1}^{n_2} \|x_j - w_2\| = \frac{1}{6} (26,94 + 21,23 + \dots + 21,78) = 26,17$$

- b. Menghitung jarak separasi antar kluster ( $M_{ij}$ ) untuk setiap pasangan vektor bobot *output neuron* saat  $i \neq j$  sesuai persamaan (2.43)

$$M_{1,2} = \|w_1 - w_2\| = \sqrt{(8,83 - 16,18)^2 + \dots + (54,46 - 36,95)^2} = 206,02$$

- c. Menghitung nilai  $R_{ij}$  untuk setiap pasangan vektor bobot *output neuron* saat  $i \neq j$  dengan persamaan (2.41)

$$R_{1,2} = \frac{S_1 + S_2}{M_{1,2}} = \frac{0,00 + 26,17}{206,02} = 0,1270$$

- d. Menghitung nilai indeks *Davies-Bouldin* hasil klusterisasi menggunakan persamaan (2.40)  
 $DB = 0,1270$

### 3. Indeks *Calinski-Harabasz*

Evaluasi hasil pengelompokan BPRS dengan indeks *Calinski-Harabasz* diperoleh dengan menghitung terlebih dahulu *sum of squares within cluster* atau jarak setiap objek data terhadap vektor bobot *output neuron*-nya dan *sum of squares between cluster* atau jarak antar vektor bobot *output neuron*. Kemudian, keduanya dapat digunakan untuk menghitung indeks *Calinski-Harabasz* hasil klusterisasi. Sebagai contoh, perhitungan nilai indeks *Calinski-Harabasz* hasil klusterisasi algoritma SOM 2 kluster dari data BPRS tanpa standarisasi dilakukan dengan tahapan sebagai berikut,

- a. Menghitung *sum of squares within cluster* atau *SSW* sesuai persamaan (2.45)

$$SSW = \sum_{i=1}^k \sum_{j=1}^{n_k} \|x_{jk} - w_k\|^2 = \sum_{i=1}^k \left( \sum_{j=1}^{n_1} \|x_{j1} - w_1\|^2 + \sum_{j=1}^{n_2} \|x_{j2} - w_2\|^2 \right)$$

$$SSW = ((0,00) + (725,82 + \dots + 474,49)) = (0,00 + 4424,69) = 4424,69$$

- b. Menghitung *sum of squares between cluster* atau *SSB* sesuai persamaan (2.46)

$$SSB = \sum_{i=1}^k n_k \times \|w_k - c\|^2 = (n_1 \times \|w_1 - c\|^2) + (n_2 \times \|w_2 - c\|^2)$$

$$SSB = (1 \times 31184,50) + (6 \times 866,24) = 36381,91$$

- c. Menghitung nilai indeks *Calinski-Harabasz* hasil klusterisasi sesuai persamaan (2.44)

$$CH = \frac{SSB}{SSW} \times \frac{(n - k)}{(k - 1)} = \frac{36381,91}{4424,69} \times \frac{(7 - 2)}{(2 - 1)} = 41,11$$

Evaluasi hasil *clustering* algoritma SOM dalam pengelompokan BPRS menggunakan indeks *Silhouette*, *Davies-Bouldin*, dan *Calinski-Harabasz* secara lengkap disajikan pada Tabel 4.30.

**Tabel 4.30** Evaluasi Hasil Klusterisasi BPRS dengan Algoritma SOM

Bank	z-score	Jumlah Kluster	Nilai Validasi		
			Sil	DB	CH
BPRS	Tanpa	2	0,6907	0,1270	41,1124
		3	0,3197	0,4943	40,3453
	Dengan	2	0,3449	0,9535	4,8282
		3	0,3395	0,5848	4,0811

Kemudian dilakukan pemilihan hasil klusterisasi BPRS terbaik berdasarkan nilai validasi *Sil* paling mendekati 1 (Zhao, dkk., 2023), *DB* terkecil (Davies dan Bouldin, 1979), dan *CH* terbesar (Ros, dkk., 2023). Berdasarkan Tabel 4.30, analisis *clustering* BPRS dengan algoritma SOM menghasilkan pengelompokan terbaik saat kluster berjumlah 2 kelompok dengan data tanpa proses standarisasi. Bobot *output neuron* hasil klusterisasi SOM terbaik disajikan pada Tabel 4.31.

**Tabel 4.31** Bobot *Output Neuron* SOM Hasil Klusterisasi BPRS Terbaik

w	Variabel			
	NPL	LDR	NI	KPMM
1	10,37	225,05	9,35	44,23
2	5,38	118,57	3,67	30,75

Selanjutnya dilakukan perhitungan jarak tiap objek data terhadap seluruh vektor bobot *output neuron* yang dihasilkan seperti halnya pada Tabel 4.31. Hasil perhitungan jarak seluruh data BPRS terhadap seluruh vektor bobot yang terbentuk disajikan secara lengkap pada Tabel 4.32.

**Tabel 4.32** Jarak Terhadap Bobot dari Hasil Klasterisasi BPRS Terbaik dengan SOM

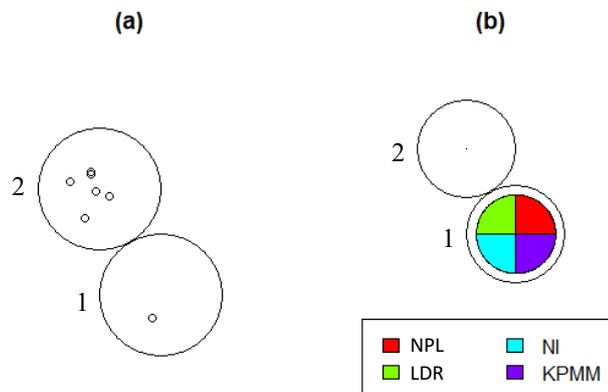
Nama BPRS	$d_{w_1, x_n}$	$d_{w_2, x_n}$
PT BPRS Amanah Sejahtera	137,66	31,40
PT BPRS Mandiri Mitra Sukses	118,57	21,14
PT BPRS Karya Mugi Sentosa	106,38	2,34
PT BPRS Baktimakmur Indah	135,49	45,71
PT BPRS Annisa Mukti	92,21	37,79
PT BPRS Unawi Barokah	92,21	199,65
PT BPRS Madinah	105,30	29,67

Jarak pada Tabel 4.32 merupakan bahan pertimbangan bagi algoritma SOM dalam mengkategorikan objek data ke suatu kluster. Sebagai contoh, PT BPRS Amanah Sejahtera dikelompokkan ke kluster 2 karena memiliki jarak terhadap vektor bobot ke-2 paling minimum yakni 31,40 dibandingkan jarak terhadap kluster 1. Sedangkan PT BPRS Unawi Barokah dikelompokkan ke kluster 1 karena memiliki jarak terhadap vektor bobot ke-1 paling minimum yakni 92,91 dibandingkan jarak terhadap kluster 2. Hasil klasterisasi BPRS dengan algoritma SOM secara lengkap dapat dilihat pada Tabel 4.33. Selain itu, hasil klasterisasi secara visual disajikan pada Gambar 4.8.

**Tabel 4.33** Hasil Klasterisasi BPRS Terbaik dengan SOM

Kluster	Anggota Kluster	
	Nama Kabupaten/Kota	Nama Bank Pembiayaan Rakyat Syariah
1 (1 anggota)	Kabupaten Sidoarjo	PT BPRS Unawi Barokah
	Kabupaten Gresik	PT BPRS Amanah Sejahtera, PT BPRS Mandiri Mitra Sukses
2 (6 anggota)	Kota Surabaya	PT BPRS Karya Mugi Sentosa
	Kabupaten Sidoarjo	PT BPRS Baktimakmur Indah
	Kabupaten Sidoarjo	PT BPRS Annisa Mukti
	Kabupaten Lamongan	PT BPRS Madinah

Pada pengelompokan BPRS dengan algoritma SOM menjadi 2 kluster dari data tanpa proses standarisasi, kluster pertama hanya beranggotakan 1 BPRS sedangkan kluster kedua terisi 6 BPRS lainnya.



**Gambar 4.8** Plot Mapping (a) dan Codes (b) Hasil Klasterisasi BPRS Terbaik

Pada plot *codes* hasil algoritma SOM, adanya diagram kipas menunjukkan variabel di kluster tersebut lebih dominan dibandingkan pada kluster lain. Berdasarkan Gambar 4.8 (b), klasterisasi BPRS dengan algoritma SOM mengkategorikan BPRS dengan variabel NPL, FDR, NI dan KPMM yang lebih besar ke dalam kluster 1. Sedangkan BPRS dengan nilai keempat variabel lebih kecil dikelompokkan ke dalam kluster 2.

#### 4.8. Evaluasi Hasil Klasterisasi

Pengevaluasian hasil klasterisasi dilakukan untuk mengetahui seberapa baik kluster yang terbentuk dengan penerapan algoritma *k-means*, *fuzzy c-means*, dan *Self-Organizing Map* (SOM). Evaluasi hasil klasterisasi mengacu pada data pengelompokan yang dihasilkan dengan ketiga algoritma *clustering*. Nilai validasi internal tiap metode *clustering* ditampilkan pada Tabel 4.34.

**Tabel 4.34** Perbandingan Nilai Evaluasi Kluster Ketiga Metode

Bank	Metode	<i>z-score</i>	Jumlah Kluster	Nilai Validasi Internal			
				<i>Sil</i>	<i>DB</i>	<i>CH</i>	
BPR	<i>k-means</i>	Tanpa	3	0,9157	0,0784	598,2775	
			4	0,5527	0,4331	645,2175	
			5	0,5494	0,5052	172,0722	
		Dengan	3	0,3348	1,1044	23,7591	
			4	0,3242	0,9781	23,9929	
			5	0,3267	0,9685	25,3000	
	<i>fuzzy c-means</i>	Tanpa	3	0,9788	0,0784	598,2775	
			4	0,7263	0,5032	619,6319	
			5	0,7140	0,4715	706,2614	
		Dengan	3	0,3239	1,6944	17,3322	
			4	0,2416	1,5273	16,4171	
			5	0,2842	1,6871	13,7156	
		SOM	Tanpa	3	0,5486	0,6474	273,7274
				4	0,3183	1,2126	87,6721
				5	0,2164	0,9528	154,6464
Dengan	3		0,2876	1,4407	8,8811		
	4		0,1174	1,6418	10,0999		
	5		0,3424	0,9281	24,9799		
BPRS	<i>k-means</i>	Tanpa	2	0,6907	0,1270	41,1124	
			3	0,2916	0,5821	42,1825	
		Dengan	2	0,3449	0,9535	4,8282	
	3		0,3122	0,6679	4,3206		
	<i>fuzzy c-means</i>	Tanpa	2	0,8168	0,1270	41,1124	
			3	0,5098	0,5822	42,1826	
		Dengan	2	0,5483	0,9535	4,8282	
			3	0,4491	0,6679	4,3206	
		SOM	Tanpa	2	0,6907	0,1270	41,1124
3				0,3197	0,4943	40,3453	
Dengan	2		0,3449	0,9535	4,8282		
	3	0,3395	0,5848	4,0811			

Dalam menentukan jumlah kluster terbaik, akan digunakan validasi internal dengan indeks *Silhouette*, indeks *Davies-Bouldin*, dan indeks *Calinski-Harabasz*. Hasil klasterisasi terbaik

dievaluasi berdasarkan nilai indeks *Silhouette* yang nilainya mendekati 1 berdasarkan perhitungan persamaan (2.39) (Zhao, dkk., 2023), nilai indeks *Davies-Bouldin* yang menyatakan nilainya mendekati 0 berdasarkan perhitungan persamaan (2.40) (Davies dan Bouldin, 1979), serta nilai indeks *Calinski-Harabasz* tertinggi berdasarkan perhitungan persamaan (2.44) (Ros, dkk., 2023).

Hasil nilai validasi internal pada Tabel 4.34 menunjukkan bahwa untuk data BPR, indeks *Silhouette* yang nilainya paling mendekati 1 terletak pada metode *fuzzy c-means* 3 kluster dengan data tanpa standarisasi yakni sebesar 0,9788. Pada metode tersebut pula, nilai indeks *Davies-Bouldin* paling mendekati 0 yaitu 0,0784, serta nilai indeks *Calinski-Harabasz* cukup tinggi yakni sebesar 598,2775. Begitu juga untuk BPRS, indeks *Silhouette* yang nilainya paling mendekati 1 terletak pada metode *fuzzy c-means* 2 kluster dengan data tanpa standarisasi yakni sebesar 0,8168. Pada metode yang sama, nilai indeks *Davies-Bouldin* paling mendekati 0 yakni 0,1270, dan nilai indeks *Calinski-Harabasz* juga cukup tinggi yakni sebesar 41,1124. Dengan demikian dari hasil evaluasi klusterisasi berdasarkan nilai validasi internal, klusterisasi terbaik untuk BPR dan BPRS di wilayah Surabaya Raya diperoleh dengan algoritma *fuzzy c-means*, dengan data tanpa standarisasi, serta jumlah kluster sebanyak 3 untuk BPR dan 2 untuk BPRS.

#### 4.9. Interpretasi Hasil Kluster Terbaik

Interpretasi dilakukan pada hasil klusterisasi terbaik yang telah diperoleh pada tahap evaluasi hasil klusterisasi. Interpretasi dilakukan dengan menganalisis karakteristik masing-masing kluster berdasarkan variabel-variabel pembentuknya untuk memahami pola atau kecenderungan dari proses analisis *clustering*. Interpretasi hasil kluster akan ditinjau dari dua aspek, yakni secara visual menggunakan *boxplot* dan juga secara matematis dengan meninjau hasil pusat kluster atau *centroid*.

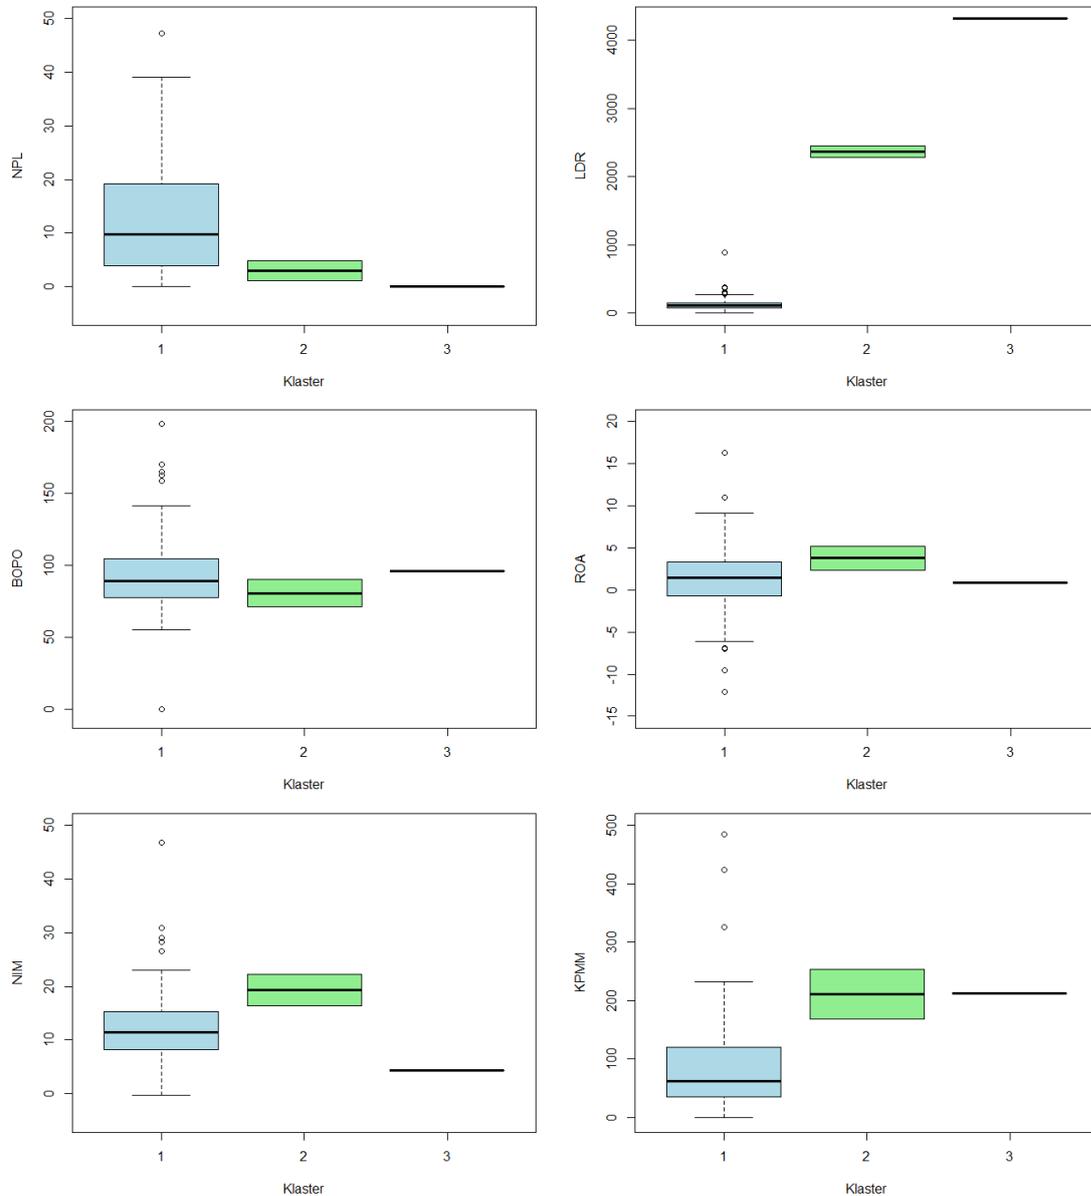
##### 4.9.1. BPR

Hasil klusterisasi BPR menggunakan algoritma *fuzzy c-means*, dengan data tanpa standarisasi, serta jumlah kluster sebanyak 3, dapat dilihat secara lebih detail pada Tabel 4.21. Kluster pertama berisi 81 anggota kluster yang terdiri atas 9 BPR di Kabupaten Gresik, 2 BPR di Kabupaten Bangkalan, 8 BPR di Kabupaten Mojokerto, 2 BPR di Kota Mojokerto, 15 BPR di Kota Surabaya, 39 BPR di Kabupaten Sidoarjo, serta 6 BPR di Kabupaten Lamongan. Selanjutnya, kluster kedua terdiri atas 2 BPR di Kabupaten Gresik. Terakhir, 1 BPR di Kota Surabaya merupakan anggota kluster ketiga. Untuk mengetahui karakteristik dari kluster yang terbentuk, digunakan *boxplot* untuk perbandingan kluster 1, kluster 2, dan kluster 3 sebagaimana pada Gambar 4.9.

Berdasarkan *boxplot* pada Gambar 4.9, dalam hal penyebaran data, variabel-variabel dalam kluster 1 memiliki data yang lebih menyebar dibanding dua kluster lainnya. Sebaliknya, variabel-variabel dalam kluster 3 sama sekali tidak memiliki persebaran data dikarenakan hanya beranggotakan 1 BPR. Apabila ditinjau dari nilai pertengahan atau median, variabel-variabel yang secara visualisasi memiliki perbedaan nilai median yang signifikan antar klasternya adalah variabel LDR dan NIM. Sedangkan pada variabel NPL, BOPO, ROA, dan KPMM, nilai median di masing-masing kluster menunjukkan bahwa nilai mediannya tidak memiliki perbedaan yang signifikan.

Selain itu, pada Gambar 4.9 nilai *outlier* hanya ditemukan pada variabel-variabel dalam kluster 1. Adanya *outlier* menunjukkan bahwa terdapat suatu data yang secara signifikan berbeda dari data-data lain dalam kluster yang sama. Adanya *outlier* dalam kluster 1 mengakibatkan kluster memiliki batas-batas antar kluster yang kurang jelas sehingga lebih sulit untuk memisahkan kluster 1 secara akurat dari dua kluster lainnya. Akan tetapi dampak tersebut bisa saja tidak terjadi sebab proporsi jumlah *outlier* terhadap keseluruhan data tidak terlalu

tinggi. Dalam hal kesimetrisan sebaran data pada kluster 1, variabel NPL dan KPMM memiliki *outlier* di bagian atas *boxplot* dan garis *whisker* bagian atas yang lebih panjang. Hal itu menunjukkan bahwa distribusi data variabel-variabel tersebut cenderung menjulur ke arah kanan atau *positive skewness*.



**Gambar 4.9** *Boxplot* Ketiga Cluster pada 6 Variabel BPR

Selain deskriptif data secara visual, interpretasi hasil klasterisasi BPR terbaik dapat ditinjau dengan membandingkan *centroid* atau pusat kluster yang terbentuk pada Tabel 4.19 dan batasan yang ditetapkan dalam Peraturan Otoritas Jasa Keuangan. Pada variabel NPL atau dari aspek risiko kredit macet, kluster 2 dan 3 dapat didefinisikan baik karena memiliki nilai NPL di bawah batas maksimum peraturan OJK. Hal tersebut menunjukkan bahwa BPR-BPR dalam kedua kluster tersebut memiliki kemampuan mencegah terjadinya kredit macet yang lebih baik dibanding BPR pada kluster 1. Selanjutnya, pada variabel LDR yang juga mewakili faktor profil risiko, ketiga kluster memiliki nilai LDR yang terlampaui tinggi. Nilai-nilai tersebut jauh diatas standar maksimal nilai LDR 90%. Oleh karenanya dapat dikatakan bahwa BPR di wilayah Surabaya Raya cenderung lebih banyak menyalurkan kredit saat dibandingkan dengan jumlah dana dan modal yang digunakan.

Efisiensi operasional yang diukur dengan variabel BOPO menjelaskan semakin rendah nilainya semakin baik. Pada ketiga klaster, nilai BOPO paling rendah berada di klaster 2 dengan nilai 81,03% yang berarti BPR pada klaster 2 mampu mengelola operasional secara baik. Sedangkan pada klaster 1 dan 3, nilai BOPO melewati batas maksimal 85% yang telah ditentukan. Pada variabel keempat yakni ROA, semakin tinggi nilai ROA kemampuan menghasilkan keuntungan juga semakin baik. Standar nilai ROA untuk dikatakan baik adalah lebih dari 2%. Jika dilihat dari ketiga klaster, klaster yang memiliki nilai ROA paling tinggi adalah pada klaster 2 dengan nilai ROA 3,70%. Sedangkan untuk nilai ROA paling rendah terdapat pada klaster 3 dengan nilai 0,82% yang berarti kemampuan BPR dalam menghasilkan keuntungan sangat rendah.

Kemudian, variabel NIM yang juga mengukur kemampuan BPR memperoleh keuntungan memiliki arti semakin tinggi nilainya semakin baik. Dari ketiga klaster yang ada, nilai NIM tertinggi terdapat pada klaster 2 dengan nilai 19,22%. Sedangkan pada klaster 3, NIM memiliki nilai 4,34% yang mana berada di bawah batas minimum 10% yang ditetapkan OJK. Terakhir berdasarkan variabel KPMM atau aspek kecukupan modal, ketiga klaster secara umum dapat didefinisikan baik karena memiliki nilai KPMM di atas batas minimum 15%. Hal tersebut menunjukkan BPR di wilayah Surabaya Raya memiliki kemampuan yang baik untuk menyerap potensi kerugian di masa mendatang. Nilai KPMM paling tinggi dimiliki oleh klaster 3 dengan nilai sebesar 212,04%.

Berdasarkan nilai *centroid* atau pusat klaster yang terbentuk pada Tabel 4.19 dan kaitannya dengan batasan kinerja keuangan yang ditetapkan oleh Otoritas Jasa Keuangan, dilakukan pemeringkatan 3 tingkat pada variabel-variabel tiap klaster. Hasil pemeringkatan tersebut dapat dilihat pada Tabel 4.35.

**Tabel 4.35** Interpretasi Hasil Klaster BPR

Kluster	Jumlah Anggota	Variabel						Kategori Kluster
		NPL	LDR	BOPO	ROA	NIM	KPMM	
1	81	Kurang Baik	Baik	Cukup Baik	Cukup Baik	Cukup Baik	Kurang Baik	Cukup Baik
2	2	Cukup Baik	Cukup Baik	Baik	Baik	Baik	Cukup Baik	Baik
3	1	Baik	Kurang Baik	Kurang Baik	Kurang Baik	Kurang Baik	Baik	Kurang Baik

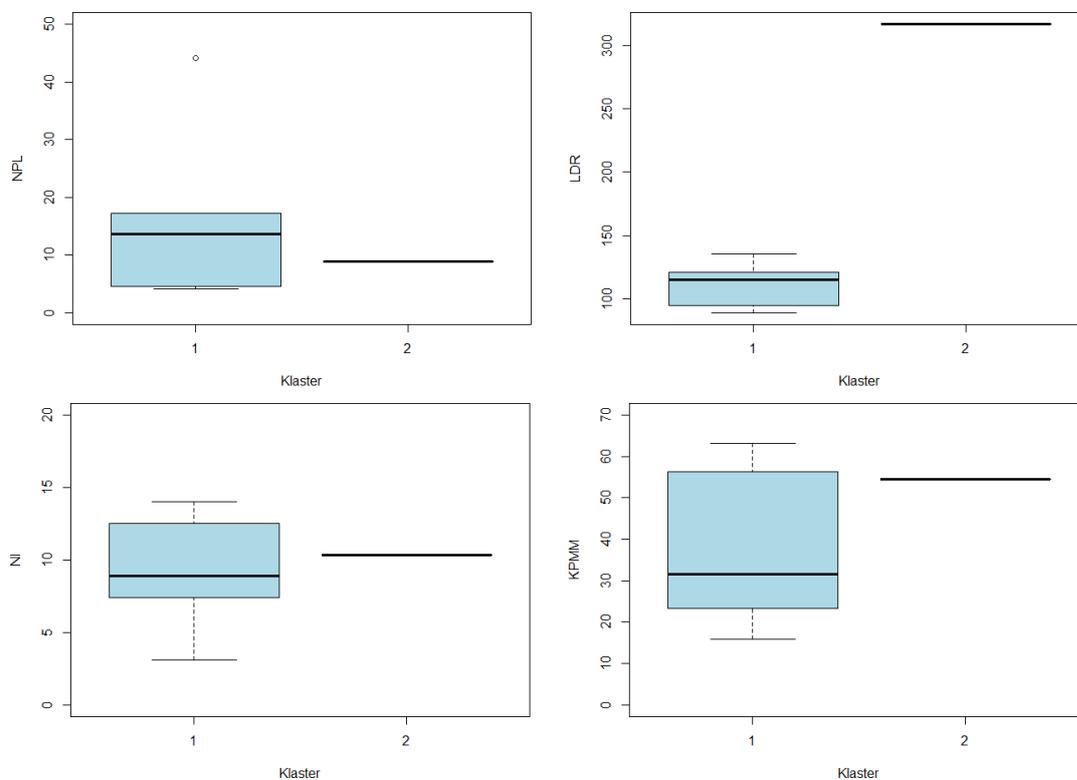
Berdasarkan Tabel 4.35 diperoleh kesimpulan bahwa klaster 2 merupakan klaster dengan kinerja keuangan baik. Hal tersebut dikarenakan, klaster tersebut memiliki nilai variabel baik pada tiga dari enam variabel yang digunakan yaitu, BOPO, ROA, NIM. Untuk klaster 1 yang beranggotakan 81 BPR, terdapat beberapa variabel yang bernilai cukup baik yakni, BOPO, ROA, dan NIM. Sedangkan untuk klaster 3 yang hanya beranggotakan 1 BPR, BPR tersebut berada pada klaster 3 karena memiliki nilai LDR, BOPO, ROA, NIM yang kurang baik.

Secara keseluruhan berdasarkan kondisi kinerja keuangan, seluruh BPR di wilayah Surabaya Raya sudah mampu mengelola nilai KPMM yang ada secara baik. Nilai rata-rata KPMM pada seluruh klaster sebagaimana terlampir pada Tabel 4.19 telah bernilai di atas batasan minimal yang ditentukan oleh OJK. Di sisi lain, seluruh BPR di wilayah Surabaya Raya masih memiliki kendala dalam mengelola nilai LDR yang ada. Nilai rata-rata LDR pada seluruh klaster sebagaimana terlampir pada Tabel 4.19 masih di atas batasan maksimal yang ditentukan oleh OJK. Oleh karenanya, BPR di wilayah Surabaya Raya masih perlu meminimalkan nilai LDR agar risiko likuiditas yang dimiliki dapat semakin ditekan. Rasio LDR dapat diminimalkan dengan beberapa strategi manajemen risiko salah satunya ialah

menyeimbangkan komposisi jumlah kredit yang diberikan terhadap jumlah dana pihak ketiga yang digunakan pada operasional perbankan. Apabila BPR ingin menyalurkan kredit dalam jumlah besar, di saat yang sama BPR juga harus mampu menghimpun dana berupa tabungan dan deposito dalam jumlah besar pula.

#### 4.9.2. BPRS

Hasil klasterisasi BPRS menggunakan algoritma *fuzzy c-means*, dengan data tanpa standarisasi, serta jumlah kluster sebanyak 2, dapat dilihat secara lebih detail pada Tabel 4.25. Kluster pertama beranggotakan 6 BPRS dengan rincian 2 BPRS di Kabupten Gresik, 1 BPRS di Kota Surabaya, 2 BPRS di Kabupaten Sidoarjo, serta 1 BPRS di Kabupaten Lamongan. Sedangkan 1 BPRS lainnya yang berada di Kabupaten Sidoarjo termasuk dalam kluster kedua. Untuk mengetahui karakteristik dari kluster yang terbentuk, digunakan *boxplot* untuk perbandingan kluster 1 dan kluster 2 sebagaimana pada Gambar 4.10.



**Gambar 4.10** *Boxplot* Kedua Cluster pada 4 Variabel BPRS

Berdasarkan *boxplot* pada Gambar 4.10, dalam hal penyebaran data, variabel-variabel dalam kluster 1 memiliki data yang lebih menyebar dibanding kluster 1. Variabel-variabel dalam kluster 2 sama sekali tidak memiliki persebaran data dikarenakan hanya beranggotakan 1 BPRS. Apabila ditinjau dari nilai pertengahan atau median, variabel-variabel yang secara visualisasi memiliki perbedaan nilai median yang signifikan antar klasternya adalah variabel LDR dan KPMM. Sedangkan pada variabel NPL dan NI, nilai median di masing-masing kluster menunjukkan bahwa nilai mediannya tidak memiliki perbedaan yang signifikan.

Selain itu, dari *boxplot* pada gambar 4.10 ditemukan nilai *outlier* pada variabel NPL dalam kluster 1. Adanya *outlier* menunjukkan bahwa terdapat suatu data yang secara signifikan berbeda dari data-data lain dalam kluster yang sama. Adanya *outlier* dalam kluster 1 mengakibatkan kluster memiliki batas antar kluster yang kurang jelas sehingga lebih sulit untuk memisahkan kluster 1 secara akurat dari kluster 2. Akan tetapi dampak tersebut bisa saja tidak terjadi sebab jumlah *outlier* tidak terlalu banyak. Dalam hal kesimetrisan sebaran data, variabel-

variabel dalam kluster 1 tidak berasal dari distribusi normal. Hal itu dikarenakan garis-garis median pada *boxplot* tidak berada di tengah *box* serta *whisker* bagian atas dan bawah tidak memiliki panjang yang sama. Sebagai contoh, variabel NI pada kluster 1 memiliki distribusi data cenderung menjulur ke arah kiri (*negative skewness*).

Selain deskriptif data secara visual, interpretasi hasil klusterisasi BPRS terbaik dapat ditinjau dengan membandingkan *centroid* atau pusat kluster yang terbentuk pada Tabel 4.23 dan batasan yang ditetapkan dalam Peraturan Otoritas Jasa Keuangan. Pada variabel NPL atau dari aspek risiko pembiayaan, kedua kluster memiliki nilai NPL yang cukup tinggi. Nilai NPL pada kluster 1 yang sebesar 16,19% jauh lebih besar dibanding NPL pada kluster 2 yang sebesar 8,84%. Nilai-nilai tersebut cukup jauh diatas batas maksimal nilai NPL 5% yang ditetapkan oleh OJK. Hal tersebut menunjukkan bahwa BPRS di wilayah Surabaya Raya belum cukup mampu mencegah terjadinya pembiayaan macet.

Hal yang sama juga terjadi pada variabel LDR. Kedua kluster memiliki nilai LDR yang cukup tinggi. Nilai LDR pada kluster 2 yang sebesar 316,16% jauh lebih besar dibanding LDR pada kluster 1 yang sebesar 111,37%. Nilai-nilai tersebut cukup jauh diatas standar maksimal nilai LDR 90% yang ditetapkan oleh OJK. Oleh karenanya dapat dikatakan bahwa BPRS di wilayah Surabaya Raya juga memiliki risiko likuiditas yang tinggi sebab cenderung lebih banyak menyalurkan pembiayaan dibandingkan dengan jumlah dana dan modal yang dimiliki.

Kemudian, variabel NI yang mengukur kemampuan BPRS memperoleh pendapatan memiliki arti semakin tinggi nilainya semakin baik. Dari kedua kluster, nilai NI pada kluster 2 yakni 10,34% sedikit lebih tinggi dibandingkan nilai NI pada kluster 1 yang sebesar 9,10%. NI pada kluster 2 telah melampaui batas minimum 10% yang telah ditetapkan oleh OJK. Sehingga dapat disimpulkan, BPRS pada kluster 2 memiliki kemampuan yang lebih baik dalam menghasilkan pendapatan dari penyaluran dana bersih dibandingkan BPRS dalam kluster 1.

Terakhir berdasarkan variabel KPMM atau aspek kecukupan modal, kedua kluster secara umum dapat didefinisikan baik karena memiliki nilai KPMM di atas batas minimum peraturan OJK yang sebesar 15%. Hal tersebut menunjukkan BPRS di wilayah Surabaya Raya memiliki kemampuan yang baik untuk menyerap potensi kerugian di masa mendatang. Nilai KPMM paling tinggi dimiliki oleh kluster 2 dengan nilai sebesar 54,45% .

Berdasarkan nilai *centroid* atau pusat kluster yang terbentuk pada Tabel 4.23 dan kaitannya dengan batasan kinerja keuangan yang ditetapkan oleh Otoritas Jasa Keuangan, dilakukan pemeringkatan 2 tingkat pada variabel-variabel tiap kluster. Hasil pemeringkatan tersebut dapat dilihat pada Tabel 4.36.

**Tabel 4.36** Interpretasi Hasil Kluster BPRS

Kluster	Jumlah Anggota	Variabel				Kategori Kluster
		NPL	LDR	NI	KPMM	
1	6	Kurang Baik	Kurang Baik	Kurang Baik	Baik	Kurang Baik
2	1	Kurang Baik	Kurang Baik	Baik	Baik	Baik

Berdasarkan pemeringkatan pada Tabel 4.36 diperoleh kesimpulan bahwa kluster 2 merupakan kluster dengan kinerja keuangan baik. Hal tersebut dikarenakan, kluster tersebut memiliki nilai variabel baik pada dua dari empat variabel yang digunakan yaitu NI dan KPMM. Sebaliknya, 6 BPRS yang berada di kluster 1 memiliki rata-rata nilai NI yang kurang baik jika dibandingkan dengan BPRS pada kluster 2. Secara keseluruhan berdasarkan kondisi kinerja keuangan, seluruh BPRS di wilayah Surabaya Raya sudah mampu mengelola nilai KPMM yang ada secara baik. Nilai rata-rata KPMM pada seluruh kluster sebagaimana terlampir pada Tabel 4.23 telah bernilai di atas batasan minimal 15% yang ditentukan oleh Otoritas Jasa Keuangan (OJK).

Namun di sisi lain, BPRS di wilayah Surabaya Raya masih memiliki kendala dalam mengelola nilai NPL serta LDR yang ada. Nilai rata-rata NPL dan LDR pada seluruh klaster sebagaimana terlampir pada Tabel 4.23 masih di atas batasan maksimal yang ditentukan oleh Otoritas Jasa Keuangan (OJK). Oleh karenanya, BPRS di wilayah Surabaya Raya masih perlu meminimalkan nilai NPL dan LDR agar risiko pembiayaan dan risiko likuiditas yang dimiliki dapat semakin ditekan. Rasio NPL dapat diminimalkan dengan beberapa strategi manajemen risiko salah satunya adalah memperketat pengecekan dokumen pengajuan pembiayaan agar potensi terjadinya pembiayaan macet dapat diminimalisir. Begitu pula dengan rasio LDR, strategi manajemen risiko yang dapat dilakukan salah satunya adalah menyeimbangkan komposisi jumlah pembiayaan yang diberikan terhadap jumlah dana pihak ketiga yang digunakan pada operasional perbankan. Apabila BPRS ingin menyalurkan pembiayaan dalam jumlah besar, di saat yang sama BPRS juga harus mampu menghimpun dana pihak ketiga bukan bank dalam jumlah besar pula.

## BAB V PENUTUP

### 5.1. Kesimpulan

Sesuai dengan hasil analisis data dan pembahasan yang dilakukan, dapat ditarik kesimpulan sebagai berikut,

1. Kinerja keuangan BPR dan BPRS di wilayah Surabaya Raya memiliki nilai yang berbeda-beda pada tiap rasionya. Sebagian besar BPR dan BPRS di wilayah Surabaya Raya memiliki nilai rasio NPL, BOPO, ROA yang belum memenuhi batasan yang telah ditetapkan oleh Otoritas Jasa Keuangan. Sebaliknya, dari segi rasio NIM/NI dan KPMM, lebih dari separuh BPR dan BPRS di wilayah Surabaya Raya telah memenuhi batasan yang ditentukan oleh Otoritas Jasa Keuangan. Sedangkan berdasarkan rasio LDR, hampir seluruh BPR di wilayah Surabaya Raya memiliki nilai rasio LDR di bawah batas maksimum yang ditetapkan oleh Otoritas Jasa Keuangan. Akan tetapi, hampir seluruh BPRS tidak dapat memenuhi batas maksimum rasio LDR tersebut. Dengan demikian dapat disimpulkan bahwa sebagian besar BPR di wilayah Surabaya Raya memiliki kinerja yang baik pada aspek kecukupan modal, likuiditas, serta kemampuan memperoleh keuntungan. Akan tetapi, pada aspek jumlah kredit macet serta manajemen operasional dan investasi, BPR di wilayah Surabaya masih memiliki kemampuan yang rendah. Kemudian, bagi sebagian besar BPRS di wilayah Surabaya Raya, meski memiliki kinerja dalam aspek kecukupan modal dan kemampuan memperoleh keuntungan terbilang baik, tetapi dalam hal risiko pembiayaan macet, manajemen operasional dan investasi, serta risiko likuiditas masih berada pada tingkat kemampuan yang kurang baik.
2. Dari hasil analisis *clustering* menggunakan algoritma *k-means* pada BPR dan BPRS di wilayah Surabaya Raya diperoleh jumlah kluster terbaik menurut nilai evaluasi kluster adalah 3 kluster untuk BPR dan 2 kluster untuk BPRS. Pada *k-means clustering*, data tanpa proses standarisasi menghasilkan nilai evaluasi kluster terbaik.
3. Berdasarkan hasil analisis *clustering* menggunakan algoritma *fuzzy c-means* diperoleh jumlah kluster terbaik menurut nilai evaluasi kluster sebanyak 3 kluster untuk BPR. Sedangkan untuk BPRS, hasil klusterisasi terbaik adalah saat kluster berjumlah 2. Pada *fuzzy c-means clustering*, data tanpa proses standarisasi juga menghasilkan nilai evaluasi kluster terbaik.
4. Dari hasil analisis *clustering* menggunakan algoritma *Self Organizing Map* (SOM) pada BPR dan BPRS di wilayah Surabaya Raya diperoleh jumlah kluster terbaik menurut nilai evaluasi kluster sebanyak 3 kluster untuk BPR serta 2 kluster untuk BPRS. Pada *SOM clustering*, data tanpa proses standarisasi juga menghasilkan nilai evaluasi kluster terbaik.
5. Klusterisasi terbaik untuk mengelompokkan BPR dan BPRS di wilayah Surabaya Raya dilakukan dengan menggunakan algoritma *fuzzy c-means*. Berdasarkan nilai evaluasi kluster menggunakan indeks *Silhouette*, indeks *Davies-Bouldin*, dan indeks *Calinski-Harabasz*, jumlah kluster optimal adalah sebanyak 3 untuk BPR dan 2 untuk BPRS. Pada pengelompokan BPR menjadi 3 kluster diperoleh nilai indeks *Silhouette* sebesar 0,9788; nilai indeks *Davies-Bouldin* sebesar 0,0784; dan nilai indeks *Calinski-Harabasz* sebesar 598,2775. Pada kluster pertama terdapat 81 BPR, kluster kedua terdiri dari 2 BPR, dan 1 BPR sisanya termasuk dalam kluster ketiga. Karakteristik hasil *clustering* BPR pada ketiga kluster adalah memiliki tingkat kesehatan cukup baik, baik, dan kurang baik secara berurutan. Pada pengelompokan BPRS menjadi 2 kluster diperoleh nilai indeks *Silhouette* sebesar 0,8168; nilai indeks *Davies-Bouldin* sebesar 0,1270; dan nilai indeks *Calinski-Harabasz* sebesar 41,1124. Pada kluster pertama terdapat 6 BPRS dan kluster kedua hanya

ada 1 BPRS. Karakteristik hasil *clustering* BPRS pada kedua kluster adalah memiliki tingkat kesehatan kurang baik dan baik secara berurutan.

## 5.2. Saran

Saran yang dapat diberikan berdasarkan hasil penelitian ini ialah sebagai berikut,

1. Bagi peneliti dengan penelitian terkait klasterisasi kinerja keuangan perbankan selanjutnya diharapkan dapat menggunakan *tuning* parameter pada ketiga algoritma untuk meninjau seberapa jauh pengaruh nilai parameter terhadap hasil klasterisasi. Selain *tuning* parameter, diharapkan pula melakukan repetisi pengambilan nilai acak *centroid* pada algoritma *fuzzy c-means* serta nilai vektor bobot pada algoritma SOM. Pengulangan nilai-nilai tersebut dilakukan untuk meninjau pengaruh pemilihan *centroid* dan vektor bobot terhadap hasil klasterisasi.
2. Bagi BPR dan BPRS di wilayah Surabaya Raya dapat menggunakan penelitian ini sebagai tolak ukur performa kinerja keuangan terhadap BPR dan BPRS lain. BPR dan BPRS yang memiliki nilai kurang optimal pada rasio berikut disarankan,
  - a. NPL: memperketat pengecekan pengajuan kredit/pembiayaan agar potensi terjadinya kredit/pembiayaan macet dapat diminimalisir.
  - b. LDR: menyeimbangkan komposisi jumlah kredit/pembiayaan yang disalurkan terhadap jumlah dana pihak ketiga yang digunakan.
  - c. BOPO: meminimalkan biaya operasional dan meningkatkan pendapatan operasional.
  - d. ROA: memperkuat kemampuan dalam memperoleh laba dalam kegiatan operasional.
  - e. NIM/NI: memperkuat kemampuan memperoleh pendapatan bunga/penyaluran dana dalam kegiatan operasional.
  - f. KPMM: menyeimbangkan komposisi modal terhadap aktiva tertimbang menurut resiko dengan menambah dan melengkapi modal atau mengurangi aktiva dengan risiko besar.
3. Bagi pemerintah khususnya Otoritas Jasa Keuangan (OJK) dapat menggunakan penelitian ini sebagai saran dalam pengawasan kinerja keuangan yang lebih intensif kepada BPR dan BPRS yang termasuk dalam kluster dengan tingkat kesehatan kurang baik.

## DAFTAR PUSTAKA

- Alam, S., Hossain, M. A., Rahman, M., & Islam, K. (2019). *Automatic Human Brain Tumor Detection in MRI Image Using Template- Automatic Human Brain Tumor Detection in MRI Image Using Template-Based K Means and Improved Fuzzy C Means Clustering Algorithm*. 3(2), 27. <https://doi.org/10.3390/bdcc3020027>
- Ashari, R. (2021). *Analisis Tingkat Kesehatan PT. Bank Sulselbar Cabang Palopo Berdasarkan Metode RGEC*. Universitas Muhammadiyah Palopo.
- Bigdeli, A., Maghsoudi, A., & Ghezelnash, R. (2022). Application of self-organizing map (SOM) and K-means clustering algorithms for portraying geochemical anomaly patterns in Moalleman district, NE Iran. *Journal of Geochemical Exploration*, 233(December 2021), 106923. <https://doi.org/10.1016/j.gexplo.2021.106923>
- Bora, D. J., & Gupta, A. K. (2014). A Comparative study Between Fuzzy Clustering Algorithm and Hard Clustering Algorithm. *International Journal of Computer Trends and Technology (IJCTT)*, 10(2), 108–113. <http://www.ijcttjournal.org/>
- Borlea, I.-D., Precup, R.-E., Borlea, A.-B., & Iercan, D. (2021). A Unified Form of Fuzzy C-Means and K-Means algorithms and its Partitional Implementation. *Knowledge-Based Systems*, 214, 106731. <https://doi.org/10.1016/j.knosys.2020.106731>
- Caliński, T., & Harabasz, J. (1974). A Dendrite Method for Cluster Analysis. *Communications in Statistics*, 3(1), 1–27. <https://doi.org/10.1080/03610927408827101>
- Chatterjee, S., & Hadi, A. (2012). *Regression Analysis by Example*. John Wiley & Sons, Inc.
- Chong, B. (2021). K-means clustering algorithm: a brief review. *Academic Journal of Computing & Information Science*, 4(5), 37–40. <https://doi.org/10.25236/AJCIS.2021.040506>
- Davies, D. L., & Bouldin, D. W. (1979). A Cluster Separation Measure. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-1(2), 224–227. <https://doi.org/10.1109/TPAMI.1979.4766909>
- Ettaouil, M., Abdelatifi, E., Belhabib, F., & El Moutaouakil, K. (2012). *Learning Algorithm of Kohonen Network With Selection Phase*. 11(11), 387–396.
- Everitt, B., Landau, S., Leese, M., & Stahl, D. (2011). *Cluster Analysis* (5th ed.). John Wiley & Sons, Inc. <https://doi.org/10.1007/BF00154794>
- Fang, J., Liu, W., Chen, L., Lauria, S., Miron, A., & Liu, X. (2023). A Survey of Algorithms, Applications and Trends for Particle Swarm Optimization. *International Journal of Network Dynamics and Intelligence*, 2(1), 24–50. <https://doi.org/https://doi.org/10.53941/ijndi0201002>
- Fitriana, A. (2024). *Buku Ajar Analisis Laporan Keuangan* (Nomor April). CV. Malik Rizki Amanah.
- Fraley, C., & Raftery, A. E. (2002). Model-Based Clustering, Discriminant Analysis, and Density Estimation. *Journal of the American Statistical Association*, 97(458), 611–631. <https://doi.org/10.1198/016214502760047131>
- Ghaseminezhad, M. H., & Karami, A. (2011). A novel self-organizing map ( SOM ) neural network for discrete groups of data clustering. *Applied Soft Computing Journal*, 11(4), 3771–3778. <https://doi.org/10.1016/j.asoc.2011.02.009>
- Gujarati, D. N. (2003). *Basic Econometrics*. (4 ed.). McGraw-Hill Inc.

<https://doi.org/10.2307/2230043>

- Guna, I. N. A. (2023). Analisis Pengelompokan Bank Umum Konvensional di Indonesia Dengan Metode K-Means Clustering. *Jurnal Ganec Swara*, 17(1), 93–99.
- Hair, J., Black, W., Babin, B., & Anderson, R. (2014). Multivariate Data Analysis. In *Australia : Cengage: Vol. 7th Editio* (7th ed.). Pearson Education.
- Harahap, A. P., & Saraswati, D. (2020). *Bank dan Lembaga Keuangan Lainnya*. CV. Jakad Media Publishing.
- Kamber, M., & Han, J. (2006). Data Mining: Concepts and Techniques : Concepts and Techniques. In *The Fundamentals of Political Science Research*.
- Kemenkeu RI, B. K. F. (2022). *Diagnosa Awal Kinerja Bank Perkreditan Rakyat dan Bank Pembiayaan Rakyat Syariah dan Potensi Usaha Mikro dan Kecil (UMK)*. [https://fiskal.kemenkeu.go.id/files/berita-kajian/file/1672296139\\_lampiran3ndpermohonanpublikasihasilkajianbprbprskepadasetbkfakajianbprbprs22122022pdf.pdf](https://fiskal.kemenkeu.go.id/files/berita-kajian/file/1672296139_lampiran3ndpermohonanpublikasihasilkajianbprbprskepadasetbkfakajianbprbprs22122022pdf.pdf)
- Khan, K. S., Yin, Y., & Jamalipour, A. (2019). On the Application of Agglomerative Hierarchical Clustering for Cache-Assisted D2D Networks. *2019 16th IEEE Annual Consumer Communications & Networking Conference (CCNC)*, 1–6. <https://doi.org/10.1109/CCNC.2019.8651785>
- Kohonen, T. (1982). Self-Organized Formation of Topologically Correct Feature Maps. *Biological Cybernetics*, 43(1), 59–69. <https://doi.org/10.1007/BF00337288>
- Kohonen, T. (2013). Essentials of the self-organizing map. *Neural Networks*, 37, 52–65. <https://doi.org/10.1016/j.neunet.2012.09.018>
- Kusumawardani, A. (2014). Analisis Perbandingan Tingkat Kesehatan Bank Dengan Menggunakan Metode CAMELS Dan RGEC Pada PT. Bank XXX Periode 2008-2011. *Jurnal Ilmiah Ekonomi Bisnis*, 19(3), 16–22.
- Larose, D. T. (2005). *Discovering Knowledge in Data*. John Wiley & Sons, Inc.
- Lobner, S., Tesfay, W. B., Nakamura, T., & Pape, S. (2016). Explainable Machine Learning for Default Privacy Setting Prediction. *IEEE Access*, 4. <https://doi.org/10.1109/ACCESS.2021.3074676>
- Otoritas Jasa Keuangan. (2024a). Statistik Perbankan Indonesia Juni 2024. In *Statistik Perbankan Indonesia* (Vol. 22, Nomor 7).
- Otoritas Jasa Keuangan. (2024b). Statistik Perbankan Syariah-Juni 2024. In *Statistik Perbankan Syariah-Juni 2024*.
- POJK Nomor 3/POJK.03/2022 Tentang Penilaian Tingkat Kesehatan Bank Perkreditan Rakyat dan Bank Pembiayaan Rakyat Syariah (2022).
- POJK Nomor 62/POJK.03/2020 Tentang Bank Perkreditan Rakyat, Otoritas Jasa Keuangan 1 (2020).
- Pristyandini, F. (2018). *Analisis Clustering Bank Umum Syariah Berdasarkan Kinerja Keuangan dan Ukuran Perusahaan (Periode 2016-2017)*. UINi Maulana Malik Ibrahim Malang.
- Puspita, B., & Pratiwi, A. (2016). *Analisis Clustering Berdasarkan Kinerja Keuangan pada Bank Pembiayaan Rakyat Syariah di Indonesia Tahun 2013-2016*. Universitas Muhammadiyah Yogyakarta.

- Putra, R. D. W., & Salim, W. (2022). Struktur Ruang Wilayah Gerbangkertosusila Berdasarkan Teori Pusat-Pinggiran: Sebuah Kajian. *Tataloka*, 24(3), 186–201. <https://doi.org/10.14710/tataloka.24.3.186-201>
- Ros, F., Riad, R., & Guillaume, S. (2023). PDBI: A partitioning Davies-Bouldin index for clustering evaluation. *Neurocomputing*, 528, 178–199. <https://doi.org/10.1016/j.neucom.2023.01.043>
- Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53–65. [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- SEOJK Nomor 1/SEOJK.03/2019 Tentang Penerapan Manajemen Risiko bagi Bank Perkreditan Rakyat, 1 (2019).
- Setiawan, K. E., Kurniawan, A., Chowanda, A., & Suhartono, D. (2023). Clustering models for hospitals in Jakarta using fuzzy c-means and k-means. *Procedia Computer Science*, 216(2022), 356–363. <https://doi.org/10.1016/j.procs.2022.12.146>
- Sudarmanto, E., Astuti, Kato, I., & Basmar, E. (2021). *Manajemen Risiko Perbankan* (1 ed.). Yayasan Kita Menulis.
- Sugar, C. A., & James, G. M. (2003). Finding the Number of Clusters in a Dataset: An Information-Theoretic Approach. *Journal of the American Statistical Association*, 98(463), 750–763. <https://doi.org/10.1198/016214503000000666>
- Undang-Undang Republik Indonesia Nomor 21 Tahun 2008 Tentang Perbankan Syariah, 64 (2008).
- Undang-Undang Republik Indonesia Nomor 7 Tahun 1992 Tentang Perbankan, 7 (1992).
- Xu, R., & Wunsch, D. C. (2009). *Clustering*. John Wiley & Sons, Inc.
- Yang, H., Ma, D., Chen, H., & Zhu, Y. (2024). Analysis of power plant outage event results based on SOM clustering. *Results in Engineering*, 21, 101995. <https://doi.org/10.1016/j.rineng.2024.101995>
- Yohannes. (2016). Analisis Perbandingan Algoritma Fuzzy C-Means dan K-Means. *Annual Research Seminar: Computer Science and Information and Communications Technology*, 2(1), 151–155.
- Zhao, W., Ma, J., Liu, Q., Song, J., Tysklind, M., Liu, C., Wang, D., Qu, Y., Wu, Y., & Wu, F. (2023). Comparison and application of SOFM, fuzzy c-means and k-means clustering algorithms for natural soil environment regionalization in China. *Environmental Research*, 216(P2), 114519. <https://doi.org/10.1016/j.envres.2022.114519>



## LAMPIRAN

### Lampiran 1 Data Rasio Kinerja Keuangan

#### a) BPR

<b>Nama BPR</b>	<b>NPL</b>	<b>LDR</b>	<b>BOPO</b>	<b>ROA</b>	<b>NIM</b>	<b>KPMM</b>
Balompanggung Sentosa	14,60	371,26	66,53	9,08	23,07	120,89
Dana Rajabally	4,80	2455,05	71,21	5,24	16,32	254,13
Rajadana Menganti	1,02	2277,97	90,16	2,31	22,28	168,47
Perumda BPR Bank Gresik	8,47	103,09	91,49	1,15	10,68	77,33
Bank Bumi Sanggabuana	3,53	218,79	97,66	0,71	12,47	197,75
Intan Kita	25,37	93,51	100,62	0,28	14,02	35,43
Aneka Dana Sejahtera	4,54	109,00	104,00	-0,69	7,65	9,00
Kebomas	11,67	888,14	93,31	1,03	15,38	34,35
Intan Nasional	47,25	119,46	122,42	-9,60	5,66	29,73
Mitra Cemawis Mandiri	4,80	83,70	77,01	3,86	13,27	22,38
Lestari Nusantara Indonesia	34,67	292,54	72,57	10,95	30,87	147,75
Perumda BPR Bangkalan	1,53	376,55	77,33	3,12	14,06	193,43
Dana Kerja Putra	14,98	144,25	133,76	-6,15	12,09	123,32
Arta Swasembada	12,40	118,51	101,06	0,36	14,65	97,69
Arta Haksaprima	8,99	284,28	55,30	16,31	46,78	102,80
Sendang Harta Sejahtera	16,84	227,55	82,90	6,85	14,44	44,47
Bumi Jaya	19,80	47,03	76,48	3,15	9,56	95,30
Mojosari Pahalpakto	15,56	148,03	82,15	3,70	13,44	78,86
Karunia Berkat Intidana	2,69	70,19	103,50	-0,81	14,74	68,62
Arta Bangsal Utama	14,06	67,35	110,94	-1,40	8,76	150,37
Puriseger Sentosa	21,80	68,23	73,04	3,06	8,45	51,58
Majatama Perseroda	5,36	179,98	70,99	4,20	9,85	38,00
Kurnia Dadi Arta	0,35	67,77	99,06	0,01	6,41	144,13
BPR Jawa Timur	8,67	85,44	91,69	0,79	7,91	35,91
Danamitra Surya	0,00	32,82	158,72	-5,01	-0,26	88,07
Kirana Indonesia	1,52	70,42	75,80	4,50	5,19	13,73
Prima Kredit Utama	3,01	143,38	84,17	3,15	12,15	45,10
Danamas	3,80	78,84	124,70	-4,47	12,84	24,57
Guna Yatra	13,55	85,31	75,31	1,75	10,77	50,73
Kosanda	0,00	0,00	170,16	-6,87	0,04	424,61
Bintang Mitra Indonesia	27,42	267,41	59,03	7,51	11,95	139,57
Central Niaga	6,54	102,50	96,06	0,39	6,22	135,07
Bina Kharisma Insani	17,27	71,23	124,48	-1,25	2,53	55,51
Surya Arthaguna Abadi	2,31	94,64	107,66	-0,90	8,22	62,09
Sili Corp Bank	17,48	155,15	83,09	1,18	6,90	129,09
Karyaperdana Sejahtera	15,92	75,34	132,18	-4,55	5,89	24,31
Permata Artha Surya	0,00	4312,90	95,91	0,82	4,32	212,25
Surya Artha Utama	2,85	138,71	80,59	2,87	9,09	45,21
Prima Master Bank	15,89	58,86	141,66	-2,76	2,92	5,32
Krian Nusantara	8,42	121,30	81,07	3,46	13,28	33,70
Sriekaya	19,20	182,48	106,94	1,27	16,46	94,62
Artha Buana	7,27	196,70	80,96	2,91	16,41	124,70
Benta Tesa	0,03	25,43	88,12	1,15	4,04	47,54
Taman Dhana	0,27	150,24	77,81	4,52	17,57	48,71
Arta Waru Surya	20,87	176,50	73,52	3,54	9,62	123,27
Satyadhana Artha	4,93	103,96	93,45	1,07	11,43	35,14
Buana Dana Makmur	4,90	108,75	81,38	2,30	6,57	48,33
Sinardana Buana	10,90	71,16	104,82	-0,24	10,45	34,75
Bandataman	5,66	263,66	101,01	-0,33	26,64	112,54

## Lampiran 1 Data Rasio Kinerja Keuangan (Lanjutan)

### a) BPR

<b>Nama BPR</b>	<b>NPL</b>	<b>LDR</b>	<b>BOPO</b>	<b>ROA</b>	<b>NIM</b>	<b>KPMM</b>
Sarana Sukses	20,55	281,95	165,36	-6,97	9,04	232,10
Berkat Cahaya Artha	22,44	146,00	124,49	-3,72	9,26	47,42
Abrin Centra Artha	31,28	125,11	198,31	-12,12	8,04	32,36
Megakerta Swadiri	31,54	253,21	98,64	0,69	12,11	132,43
Dinar Pusaka	22,70	145,78	116,32	-2,22	11,67	128,70
Bank Ima	20,77	68,66	162,86	-4,61	22,55	85,57
Gema Nusa	25,70	81,06	99,69	0,73	8,91	38,06
Toelangan Dasa Nusantara	10,84	121,46	87,87	2,14	12,39	57,29
Sari Dana Indonesia	0,00	0,00	0,00	-2,53	0,00	0,00
Taman Artha Kencana	25,70	64,81	110,27	-3,38	18,57	78,95
Padat Ganda	5,70	145,57	97,92	1,68	28,35	62,50
Sahabat Mitra Artha	1,29	38,60	76,02	5,30	16,37	1,04
Anglomas Indah	2,86	103,60	76,34	3,58	8,25	93,36
Dana Raya Jawa Timur	2,14	134,13	119,20	-3,58	8,82	10,98
Dirgadhana Arthamas	13,11	2,11	63,81	6,47	16,32	117,91
Mahkota Krian Wijaya	14,20	55,10	89,24	1,88	12,41	69,39
Wutama Artha Sejahtera	31,68	100,95	108,18	-1,29	9,29	61,08
Sentra Dana Makmur	19,30	175,31	87,75	1,65	8,60	98,12
Djojo Mandiri Raya	17,38	85,82	93,90	0,92	9,32	56,12
Puridana Arthamas	20,51	364,57	87,46	3,15	15,66	119,75
Andalan Daerah	0,00	0,00	66,11	2,20	4,83	485,63
Candisaka Arta	4,38	118,20	93,21	1,44	18,62	29,81
Mitra Majujaya Mandiri	4,75	105,59	74,88	5,00	15,16	24,62
Artamulya Bumimukti	9,68	225,95	98,52	2,49	20,28	127,90
Buduran Deltapurnam	39,08	91,17	58,91	6,95	7,42	64,27
Bumi Gora Jaya	12,68	304,96	69,25	3,34	11,51	212,97
Delta Artha Perseroda	8,10	106,06	80,94	2,05	6,04	23,63
Wiradhana Putramas	0,43	19,10	78,91	4,48	14,86	30,89
Jati Lestari	0,00	0,00	113,08	0,66	0,18	326,51
Perumda Bank Daerah Lamongan	6,55	80,13	81,54	2,15	8,99	15,25
Nusamba Brondong	13,13	104,32	90,06	2,28	15,26	33,00
Rukun karya Sari	20,03	167,40	81,42	0,91	17,34	62,01
Ulintha Ganda	2,07	145,99	85,64	5,49	29,09	66,31
Delta Lamongan	8,92	124,50	85,38	3,17	18,02	94,44
Mitra Dhnaceswara	6,81	141,38	70,54	6,46	15,58	115,04

### b) BPRS

<b>Nama BPRS</b>	<b>NPL</b>	<b>LDR</b>	<b>BOPO</b>	<b>ROA</b>	<b>NI</b>	<b>KPMM</b>
Amanah Sejahtera	10,50	88,99	97,00	0,31	9,14	23,33
Mandiri Mitra Sukses	16,62	110,12	100,02	-0,19	8,71	15,78
Karya Mugi Sentosa	4,19	119,71	86,00	2,10	3,10	32,30
Baktimakmur Indah	44,06	94,51	154,29	-4,93	7,42	30,88
Annisa Mukti	4,53	135,10	86,32	1,94	14,05	63,08
Unawi Barokah	8,83	316,67	82,32	2,47	10,34	54,46
BPRS Madinah	17,20	120,73	115,25	-2,32	12,52	56,38

## Lampiran 2 Data Rasio Kinerja Keuangan yang Distandarisasi

### a) BPR

<b>Nama BPR</b>	<b>NPL</b>	<b>LDR</b>	<b>BOPO</b>	<b>ROA</b>	<b>NIM</b>	<b>KPMM</b>
Balompanggung Sentosa	0,2738	0,2263	-0,9864	1,8317	1,4549	0,3434
Dana Rajabally	-0,6798	3,8371	-0,8212	0,9260	0,5432	1,9191
Rajadana Menganti	-1,0476	3,5302	-0,1523	0,2350	1,3482	0,9061
Perumda BPR Bank Gresik	-0,3227	-0,2383	-0,1053	-0,0386	-0,2188	-0,1717
Bank Bumi Sanggabuana	-0,8033	-0,0379	0,1125	-0,1424	0,0230	1,2523
Intan Kita	1,3217	-0,2549	0,2170	-0,2438	0,2324	-0,6673
Aneka Dana Sejahtera	-0,7051	-0,2281	0,3363	-0,4726	-0,6281	-0,9798
Kebomas	-0,0113	1,1220	-0,0411	-0,0669	0,4161	-0,6800
Intan Nasional	3,4505	-0,2010	0,9865	-2,5741	-0,8969	-0,7347
Mitra Cemawis Mandiri	-0,6798	-0,2719	-0,6165	0,6005	0,1311	-0,8216
Lestari Nusantara Indonesia	2,2265	0,0899	-0,7732	2,2728	2,5085	0,6610
Perumda BPR Bangkalan	-0,9979	0,2355	-0,6052	0,4260	0,2378	1,2013
Dana Kerja Putra	0,3107	-0,1670	1,3868	-1,7604	-0,0283	0,3721
Arta Swasembada	0,0597	-0,2116	0,2325	-0,2250	0,3175	0,0690
Arta Haksaprima	-0,2721	0,0756	-1,3829	3,5370	4,6576	0,1295
Sendang Harta Sejahtera	0,4917	-0,0227	-0,4086	1,3058	0,2891	-0,5603
Bumi Jaya	0,7797	-0,3355	-0,6352	0,4331	-0,3701	0,0408
Mojosari Pahalpacto	0,3672	-0,1605	-0,4350	0,5628	0,1541	-0,1536
Karunia Berkat Intidana	-0,8851	-0,2954	0,3186	-0,5009	0,3297	-0,2747
Arta Bangsal Utama	0,2212	-0,3003	0,5813	-0,6401	-0,4781	0,6920
Puriseger Sentosa	0,9743	-0,2987	-0,7566	0,4119	-0,5200	-0,4763
Majatama Perseroda	-0,6253	-0,1051	-0,8290	0,6807	-0,3309	-0,6369
Kurnia Dadi Arta	-1,1127	-0,2995	0,1619	-0,3075	-0,7956	0,6182
BPR Jawa Timur	-0,3032	-0,2689	-0,0983	-0,1235	-0,5929	-0,6616
Danamitra Surya	-1,1468	-0,3601	2,2680	-1,4915	-1,6965	-0,0447
Kirana Indonesia	-0,9989	-0,2950	-0,6592	0,7515	-0,9604	-0,9239
Prima Kredit Utama	-0,8539	-0,1685	-0,3637	0,4331	-0,0202	-0,5529
Danamas	-0,7771	-0,2804	1,0670	-1,3642	0,0730	-0,7957
Guna Yatra	0,1716	-0,2692	-0,6765	0,1029	-0,2066	-0,4863
Kosanda	-1,1468	-0,4170	2,6718	-1,9302	-1,6560	3,9352
Bintang Mitra Indonesia	1,5211	0,0464	-1,2512	1,4614	-0,0472	0,5643
Central Niaga	-0,5104	-0,2394	0,0560	-0,2179	-0,8212	0,5111
Bina Kharisma Insani	0,5335	-0,2935	1,0592	-0,6047	-1,3197	-0,4298
Surya Arthaguna Abadi	-0,9220	-0,2530	0,4655	-0,5221	-0,5511	-0,3520
Sili Corp Bank	0,5540	-0,1481	-0,4019	-0,0316	-0,7294	0,4404
Karyaperdana Sejahtera	0,4022	-0,2864	1,3311	-1,3830	-0,8658	-0,7988
Permata Artha Surya	-1,1468	7,0563	0,0507	-0,1165	-1,0779	1,4238
Surya Artha Utama	-0,8695	-0,1766	-0,4901	0,3670	-0,4335	-0,5516
Prima Master Bank	0,3993	-0,3150	1,6657	-0,9608	-1,2670	-1,0233
Krian Nusantara	-0,3275	-0,2068	-0,4732	0,5062	0,1324	-0,6877
Sriekaya	0,7213	-0,1008	0,4401	-0,0103	0,5620	0,0327
Artha Buana	-0,4394	-0,0761	-0,4770	0,3765	0,5552	0,3884
Benta Tesa	-1,1439	-0,3729	-0,2243	-0,0386	-1,1157	-0,5240
Taman Dhana	-1,1205	-0,1566	-0,5882	0,7562	0,7119	-0,5102
Arta Waru Surya	0,8838	-0,1111	-0,7397	0,5251	-0,3619	0,3715
Satyadhana Artha	-0,6671	-0,2368	-0,0361	-0,0575	-0,1175	-0,6707
Buana Dana Makmur	-0,6700	-0,2285	-0,4622	0,2326	-0,7739	-0,5147
Sinardana Buana	-0,0862	-0,2937	0,3652	-0,3665	-0,2498	-0,6753
Bandataman	-0,5961	0,0399	0,2307	-0,3877	1,9371	0,2446

**Lampiran 2 Data Rasio Kinerja Keuangan yang Distandarisasi (Lanjutan)**

a) BPR

<b>Nama BPR</b>	<b>NPL</b>	<b>LDR</b>	<b>BOPO</b>	<b>ROA</b>	<b>NIM</b>	<b>KPMM</b>
Bandataman	-0,5961	0,0399	0,2307	-0,3877	1,9371	0,2446
Sarana Sukses	0,8527	0,0716	2,5024	-1,9538	-0,4403	1,6586
Berkat Cahaya Artha	1,0366	-0,1640	1,0596	-1,1873	-0,4106	-0,5255
Abrin Centra Artha	1,8967	-0,2002	3,6655	-3,1685	-0,5754	-0,7036
Megakerta Swadiri	1,9220	0,0218	0,1471	-0,1471	-0,0256	0,4799
Dinar Pusaka	1,0619	-0,1644	0,7712	-0,8335	-0,0850	0,4358
Bank Ima	0,8741	-0,2980	2,4141	-1,3972	1,3846	-0,0743
Gema Nusa	1,3538	-0,2765	0,1841	-0,1377	-0,4579	-0,6362
Toelangan Dasa Nusantara	-0,0921	-0,2065	-0,2331	0,1949	0,0122	-0,4087
Sari Dana Indonesia	-1,1468	-0,4170	-3,3350	-0,9066	-1,6614	-1,0863
Taman Artha Kencana	1,3538	-0,3047	0,5576	-1,1071	0,8470	-0,1526
Padat Ganda	-0,5922	-0,1647	0,1216	0,0864	2,1681	-0,3471
Sahabat Mitra Artha	-1,0213	-0,3501	-0,6514	0,9402	0,5498	-1,0739
Anglomas Indah	-0,8685	-0,2375	-0,6401	0,5345	-0,5470	0,0178
Dana Raya Jawa Timur	-0,9386	-0,1846	0,8729	-1,1543	-0,4700	-0,9564
Dirgadhana Arthamas	0,1288	-0,4133	-1,0825	1,2161	0,5431	0,3081
Mahkota Krian Wijaya	0,2348	-0,3215	-0,1848	0,1335	0,0149	-0,2656
Wutama Artha Sejahtera	1,9357	-0,2421	0,4838	-0,6141	-0,4065	-0,3639
Sentra Dana Makmur	0,7311	-0,1132	-0,2374	0,0793	-0,4997	0,0741
Djojo Mandiri Raya	0,5442	-0,2683	-0,0203	-0,0929	-0,4025	-0,4226
Puridana Arthamas	0,8488	0,2147	-0,2476	0,4331	0,4539	0,3299
Andalan Daerah	-1,1468	-0,4170	-1,0013	0,2090	-1,0090	4,6568
Candisaka Arta	-0,7206	-0,2122	-0,0446	0,0298	0,8538	-0,7337
Mitra Majujaya Mandiri	-0,6846	-0,2340	-0,6917	0,8694	0,3864	-0,7951
Artamulya Bumimukti	-0,2049	-0,0255	0,1428	0,2774	1,0780	0,4263
Buduran Deltapurnam	2,6556	-0,2590	-1,2554	1,3294	-0,6591	-0,3262
Bumi Gora Jaya	0,0869	0,1114	-0,8904	0,4779	-0,1066	1,4323
Delta Artha Perseroda	-0,3587	-0,2332	-0,4778	0,1736	-0,8455	-0,8069
Wiradhana Putramas	-1,1050	-0,3839	-0,5494	0,7468	0,3459	-0,7209
Jati Lestari	-1,1468	-0,4170	0,6568	-0,1542	-1,6371	2,7751
Perumda Bank Daerah Lamongan	-0,5095	-0,2781	-0,4566	0,1972	-0,4470	-0,9059
Nusamba Brondong	0,1307	-0,2362	-0,1558	0,2279	0,3999	-0,6960
Rukun karya Sari	0,8021	-0,1269	-0,4608	-0,0952	0,6809	-0,3529
Ulintha Ganda	-0,9454	-0,1640	-0,3118	0,9850	2,2681	-0,3021
Delta Lamongan	-0,2789	-0,2012	-0,3210	0,4378	0,7727	0,0306
Mitra Dhnaceswara	-0,4842	-0,1720	-0,8449	1,2138	0,4431	0,2742

b) BPRS

<b>Nama BPRS</b>	<b>NPL</b>	<b>LDR</b>	<b>BOPO</b>	<b>ROA</b>	<b>NI</b>	<b>KPMM</b>
Amanah Sejahtera	-0,3366	-0,6551	-0,2389	0,1471	-0,0521	-0,8801
Mandiri Mitra Sukses	0,1080	-0,3881	-0,1192	-0,0374	-0,1726	-1,2921
Karya Mugi Sentosa	-0,7951	-0,2669	-0,6748	0,8078	-1,7452	-0,3906
Baktimakmur Indah	2,1017	-0,5853	2,0315	-1,7870	-0,5342	-0,4681
Annisa Mukti	-0,7704	-0,0724	-0,6621	0,7488	1,3243	1,2890
Unawi Barokah	-0,4579	2,2219	-0,8207	0,9444	0,2843	0,8186
BPRS Madinah	0,1502	-0,2540	0,4843	-0,8236	0,8954	0,9234

**Lampiran 3** Data Lengkap Jarak dari Hasil Klusterisasi BPR Terbaik dengan *K-means*

<b>Nama BPR</b>	$d_{c_1, x_n}$	$d_{c_2, x_n}$	$d_{c_3, x_n}$
Balongpanggung Sentosa	1997,39	378,94	3942,89
Dana Rajabally	98,88	1819,83	1858,54
Rajadana Menganti	98,88	1646,25	2035,49
Perumda BPR Bank Gresik	2267,43	610,07	4211,99
Bank Bumi Sanggabuana	2147,84	469,11	4094,15
Intan Kita	2280,00	631,54	4223,18
Aneka Dana Sejahtera	2266,71	629,97	4208,82
Kebomas	1489,01	394,77	3429,42
Intan Nasional	2255,28	606,89	4197,77
Mitra Cemawis Mandiri	2290,63	652,43	4233,52
Lestari Nusantara Indonesia	2075,25	425,67	4021,19
Perumda BPR Bangkalan	1990,05	343,48	3936,45
Dana Kerja Putra	2224,70	546,56	4169,81
Arta Swasembada	2250,99	586,21	4195,99
Arta Haksaprima	2085,44	457,98	4030,57
Sendang Harta Sejahtera	2145,51	519,77	4088,87
Bumi Jaya	2322,46	658,30	4267,57
Mojosari Pahalpacto	2222,47	572,13	4167,07
Karunia Berkat Intidana	2300,87	639,67	4245,16
Arta Bangsal Utama	2300,22	616,04	4246,05
Puriseger Sentosa	2303,94	655,08	4247,83
Majatama Perseroda	2193,43	566,39	4136,68
Kurnia Dadi Arta	2299,84	620,89	4245,68
BPR Jawa Timur	2287,87	641,57	4231,15
Danamitra Surya	2338,34	657,80	4282,35
Kirana Indonesia	2304,62	668,47	4247,17
Prima Kredit Utama	2229,35	589,83	4172,89
Danamas	2295,72	644,45	4238,33
Guna Yatra	2286,89	639,90	4230,75
Kosanda	2377,89	667,36	4318,77
Bintang Mitra Indonesia	2100,60	456,46	4046,42
Central Niaga	2265,39	591,54	4211,11
Bina Kharisma Insani	2301,09	638,90	4244,70
Surya Arthaguna Abadi	2276,96	619,57	4220,95
Sili Corp Bank	2212,97	548,76	4158,64
Karyaperdana Sejahtera	2299,46	646,01	4241,91
Permata Artha Surya	1946,51	3672,03	0,00
Surya Artha Utama	2234,01	595,02	4177,56
Prima Master Bank	2317,73	667,08	4259,35
Krian Nusantara	2252,24	614,06	4195,45
Sriekaya	2187,37	528,44	4132,17
Artha Buana	2171,54	513,96	4117,18
Benta Tesa	2346,87	691,86	4290,64
Taman Dhana	2222,23	584,24	4165,93
Arta Waru Surya	2191,89	534,47	4137,47
Satyadhana Artha	2269,45	625,29	4212,67
Buana Dana Makmur	2263,67	619,33	4207,37
Sinardana Buana	2302,29	651,11	4245,48
Bandataman	2105,28	453,61	4050,54

**Lampiran 3** Data Lengkap Jarak dari Hasil Klasterisasi BPR Terbaik dengan *K-means* (Lanjutan)

<b>Nama BPR</b>	<b><math>d_{c_1, x_n}</math></b>	<b><math>d_{c_2, x_n}</math></b>	<b><math>d_{c_3, x_n}</math></b>
Sarana Sukses	2086,51	383,49	4031,66
Berkat Cahaya Artha	2227,10	575,44	4170,32
Abrin Centra Artha	2251,87	588,37	4193,04
Megakerta Swadiri	2115,06	455,47	4060,61
Dinar Pusaka	2222,66	547,35	4168,08
Bank Ima	2302,84	622,46	4246,75
Gema Nusa	2292,22	641,89	4235,51
Toelangan Dasa Nusantara	2250,36	602,23	4194,33
Sari Dana Indonesia	2377,38	758,15	4319,19
Taman Artha Kencana	2305,82	638,34	4250,31
Padat Ganda	2226,01	575,92	4170,09
Sahabat Mitra Artha	2337,39	700,65	4279,58
Anglomas Indah	2266,01	608,82	4211,03
Dana Raya Jawa Timur	2241,72	604,24	4183,68
Dirgadhana Arthamas	2366,33	696,53	4311,98
Mahkota Krian Wijaya	2315,82	656,06	4260,23
Wutama Artha Sejahtera	2270,91	613,12	4214,80
Sentra Dana Makmur	2194,22	539,65	4139,22
Djojo Mandiri Raya	2286,07	632,30	4230,00
Puridana Arthamas	2004,12	374,68	3949,49
Andalan Daerah	2382,45	702,23	4321,66
Candisaka Arta	2255,66	614,99	4198,69
Mitra Majujaya Mandiri	2268,63	633,21	4211,56
Artamulya Bumimukti	2142,27	481,04	4087,86
Buduran Deltapurnam	2280,51	634,25	4224,67
Bumi Gora Jaya	2061,62	400,61	4008,06
Delta Artha Perseroda	2268,27	631,90	4211,10
Wiradhana Putramas	2354,34	705,27	4297,68
Jati Lestari	2369,62	665,37	4314,45
Perumda Bank Daerah Lamongan	2294,80	657,45	4237,38
Nusamba Brondong	2269,25	626,16	4212,43
Rukun karya Sari	2204,24	562,04	4148,32
Ulintha Ganda	2225,28	577,70	4169,55
Delta Lamongan	2245,07	586,30	4190,10
Mitra Dhnceswara	2227,24	569,32	4172,75

**Lampiran 4** Data Lengkap Derajat Keanggotaan Hasil Klusterisasi BPR Terbaik dengan *Fuzzy C-means*

<b>Nama BPR</b>	$\mu_{c_1}(x_n)$	$\mu_{c_2}(x_n)$	$\mu_{c_3}(x_n)$
Balompanggung Sentosa	0,9814	0,0149	0,0037
Dana Rajabally	0,0032	0,9918	0,0050
Rajadana Menganti	0,0010	0,9979	0,0011
Perumda BPR Bank Gresik	0,9997	0,0002	0,0001
Bank Bumi Sanggabuana	0,9945	0,0044	0,0012
Intan Kita	0,9989	0,0009	0,0003
Aneka Dana Sejahtera	0,9982	0,0014	0,0004
Kebomas	0,7580	0,2050	0,0370
Intan Nasional	0,9985	0,0011	0,0003
Mitra Cemawis Mandiri	0,9982	0,0014	0,0004
Lestari Nusantara Indonesia	0,9909	0,0072	0,0019
Perumda BPR Bangkalan	0,9774	0,0181	0,0045
Dana Kerja Putra	0,9992	0,0006	0,0002
Arta Swasembada	0,9999	0,0001	0,0000
Arta Haksaprima	0,9923	0,0061	0,0016
Sendang Harta Sejahtera	0,9969	0,0024	0,0006
Bumi Jaya	0,9980	0,0015	0,0004
Mojosari Pahalpakto	0,9999	0,0001	0,0000
Karunia Berkat Intidana	0,9989	0,0009	0,0003
Arta Bangsal Utama	0,9978	0,0017	0,0005
Puriseger Sentosa	0,9985	0,0012	0,0003
Majatama Perseroda	0,9986	0,0011	0,0003
Kurnia Dadi Arta	0,9980	0,0015	0,0004
BPR Jawa Timur	0,9987	0,0010	0,0003
Danamitra Surya	0,9965	0,0027	0,0008
Kirana Indonesia	0,9975	0,0019	0,0005
Prima Kredit Utama	0,9995	0,0004	0,0001
Danamas	0,9980	0,0015	0,0004
Guna Yatra	0,9990	0,0008	0,0002
Kosanda	0,9685	0,0243	0,0072
Bintang Mitra Indonesia	0,9935	0,0052	0,0014
Central Niaga	0,9991	0,0007	0,0002
Bina Kharisma Insani	0,9985	0,0011	0,0003
Surya Arthaguna Abadi	0,9994	0,0005	0,0001
Sili Corp Bank	0,9993	0,0005	0,0001
Karyaperdana Sejahtera	0,9978	0,0017	0,0005
Permata Artha Surya	0,0000	0,0000	1,0000
Surya Artha Utama	0,9995	0,0004	0,0001
Prima Master Bank	0,9964	0,0028	0,0008
Krian Nusantara	0,9992	0,0006	0,0002
Sriekaya	0,9993	0,0006	0,0002
Artha Buana	0,9984	0,0012	0,0003
Benta Tesa	0,9967	0,0025	0,0007
Taman Dhana	0,9994	0,0005	0,0001
Arta Waru Surya	0,9990	0,0008	0,0002
Satyadhana Artha	0,9991	0,0007	0,0002
Buana Dana Makmur	0,9994	0,0005	0,0001
Sinardana Buana	0,9983	0,0013	0,0004
Bandataman	0,9948	0,0041	0,0011

**Lampiran 4** Data Lengkap Derajat Keanggotaan Hasil Klasterisasi BPR Terbaik dengan *Fuzzy C-means* (Lanjutan)

<b>Nama BPR</b>	$\mu_{c_1}(x_n)$	$\mu_{c_2}(x_n)$	$\mu_{c_3}(x_n)$
Sarana Sukses	0,9858	0,0113	0,0029
Berkat Cahaya Artha	0,9993	0,0006	0,0002
Abrin Centra Artha	0,9963	0,0029	0,0008
Megakerta Swadiri	0,9951	0,0038	0,0010
Dinar Pusaka	0,9993	0,0005	0,0001
Bank Ima	0,9977	0,0018	0,0005
Gema Nusa	0,9986	0,0011	0,0003
Toelangan Dasa Nusantara	0,9997	0,0002	0,0001
Sari Dana Indonesia	0,9919	0,0063	0,0019
Taman Artha Kencana	0,9987	0,0010	0,0003
Padat Ganda	0,9997	0,0002	0,0001
Sahabat Mitra Artha	0,9959	0,0032	0,0009
Anglomas Indah	0,9996	0,0003	0,0001
Dana Raya Jawa Timur	0,9983	0,0013	0,0004
Dirgadhana Arthamas	0,9954	0,0035	0,0010
Mahkota Krian Wijaya	0,9984	0,0013	0,0004
Wutama Artha Sejahtera	0,9994	0,0005	0,0001
Sentra Dana Makmur	0,9995	0,0004	0,0001
Djojo Mandiri Raya	0,9992	0,0006	0,0002
Puridana Arthamas	0,9827	0,0138	0,0034
Andalan Daerah	0,9599	0,0310	0,0092
Candisaka Arta	0,9991	0,0007	0,0002
Mitra Majujaya Mandiri	0,9987	0,0010	0,0003
Artamulya Bumimukti	0,9971	0,0023	0,0006
Buduran Deltapurnam	0,9989	0,0009	0,0002
Bumi Gora Jaya	0,9862	0,0110	0,0028
Delta Artha Perseroda	0,9987	0,0010	0,0003
Wiradhana Putramas	0,9960	0,0031	0,0009
Jati Lestari	0,9823	0,0137	0,0040
Perumda Bank Daerah Lamongan	0,9979	0,0016	0,0005
Nusamba Brondong	0,9990	0,0008	0,0002
Rukun karya Sari	0,9995	0,0004	0,0001
Ulintha Ganda	0,9997	0,0002	0,0001
Delta Lamongan	0,9999	0,0001	0,0000
Mitra Dhnaceswara	0,9996	0,0003	0,0001

**Lampiran 5** Data Lengkap Jarak Terhadap Bobot dari Hasil Klusterisasi BPR Terbaik dengan SOM

<b>Nama BPR</b>	$d_{w_1, x_n}$	$d_{w_2, x_n}$	$d_{w_3, x_n}$
Balompanggung Sentosa	1505,43	34,87	275,82
Dana Rajabally	588,91	2118,79	2353,52
Rajadana Menganti	402,31	1937,55	2170,09
Perumda BPR Bank Gresik	1774,58	241,24	50,54
Bank Bumi Sanggabuana	1658,33	158,13	200,22
Intan Kita	1786,42	259,48	33,10
Aneka Dana Sejahtera	1772,76	253,84	28,97
Kebomas	994,56	551,32	775,84
Intan Nasional	1761,68	243,25	59,41
Mitra Cemawis Mandiri	1796,92	270,65	30,89
Lestari Nusantara Indonesia	1584,15	70,60	219,11
Perumda BPR Bangkalan	1500,51	98,10	311,47
Dana Kerja Putra	1732,89	208,93	111,88
Arta Swasembada	1758,53	225,51	71,59
Arta Haksaprima	1593,21	65,28	192,54
Sendang Harta Sejahtera	1651,96	129,15	117,11
Bumi Jaya	1830,10	295,16	95,39
Mojosari Pahalpakto	1729,63	195,71	62,85
Karunia Berkat Intidana	1807,86	276,03	61,00
Arta Bangsal Utama	1809,16	281,70	132,95
Puriseger Sentosa	1810,72	278,75	54,93
Majatama Perseroda	1699,88	174,89	70,17
Kurnia Dadi Arta	1808,61	279,20	125,09
BPR Jawa Timur	1794,31	266,20	30,41
Danamitra Surya	1845,91	322,76	124,93
Kirana Indonesia	1810,84	286,35	47,29
Prima Kredit Utama	1735,89	207,54	35,52
Danamas	1802,00	280,14	52,38
Guna Yatra	1793,62	261,98	38,08
Kosanda	1898,71	480,47	420,70
Bintang Mitra Indonesia	1609,33	85,32	193,98
Central Niaga	1773,90	243,30	108,00
Bina Kharisma Insani	1807,87	280,65	65,87
Surya Arthaguna Abadi	1783,81	253,85	44,93
Sili Corp Bank	1721,33	189,46	110,46
Karyaperdana Sejahtera	1805,76	285,19	62,32
Permata Artha Surya	2437,58	3972,87	4204,55
Surya Artha Utama	1740,58	211,95	32,53
Prima Master Bank	1823,84	308,31	83,29
Krian Nusantara	1758,64	231,50	12,67
Sriekaya	1694,78	163,82	99,78
Artha Buana	1679,74	147,20	127,92
Benta Tesa	1853,58	322,36	90,09
Taman Dhana	1728,85	199,60	43,79
Arta Waru Surya	1700,11	167,08	116,37
Satyadhana Artha	1775,86	248,71	14,56
Buana Dana Makmur	1770,32	240,17	23,01
Sinardana Buana	1808,71	281,44	47,00
Bandataman	1613,05	85,09	173,95

**Lampiran 5** Data Lengkap Jarak Terhadap Bobot dari Hasil Klasterisasi BPR Terbaik dengan SOM (Lanjutan)

<b>Nama BPR</b>	$d_{w_1, x_n}$	$d_{w_2, x_n}$	$d_{w_3, x_n}$
Sarana Sukses	1598,68	172,07	277,39
Berkat Cahaya Artha	1733,66	211,33	58,60
Abrin Centra Artha	1758,71	262,90	118,04
Megakerta Swadiri	1623,42	99,76	177,62
Dinar Pusaka	1730,96	203,48	111,66
Bank Ima	1810,32	289,08	107,24
Gema Nusa	1798,70	270,86	42,51
Toelangan Dasa Nusantara	1757,12	225,84	31,25
Sari Dana Indonesia	1884,14	364,80	145,13
Taman Artha Kencana	1813,02	281,25	76,83
Padat Ganda	1732,80	202,45	50,33
Sahabat Mitra Artha	1843,48	320,10	79,50
Anglomas Indah	1773,56	238,95	66,57
Dana Raya Jawa Timur	1747,76	233,07	45,02
Dirgadhana Arthamas	1874,56	339,99	143,88
Mahkota Krian Wijaya	1822,86	289,35	71,28
Wutama Artha Sejahtera	1777,76	248,40	50,28
Sentra Dana Makmur	1701,77	168,03	95,35
Djojo Mandiri Raya	1792,84	261,57	42,07
Puridana Arthamas	1512,04	34,59	268,64
Andalan Daerah	1906,85	513,37	471,17
Candisaka Arta	1761,97	236,52	9,96
Mitra Majujaya Mandiri	1774,94	249,05	13,80
Artamulya Bumimukti	1650,48	121,75	151,52
Buduran Deltapurnam	1787,62	255,50	61,34
Bumi Gora Jaya	1572,87	116,34	267,25
Delta Artha Perseroda	1774,56	249,45	14,95
Wiradhana Putramas	1860,81	330,98	93,71
Jati Lestari	1885,18	411,24	320,04
Perumda Bank Daerah Lamongan	1800,99	276,53	36,16
Nusamba Brondong	1775,63	248,39	13,83
Rukun karya Sari	1711,06	179,69	66,37
Ulintha Ganda	1732,18	200,13	52,08
Delta Lamongan	1752,56	217,95	67,09
Mitra Dhnaceswara	1735,28	200,83	92,51

## Lampiran 6 Script Preprocessing Data

### a) Mengimpor data, statistika deskriptif, dan standarisasi data

```
library(readxl)
Data_BPR <- read_excel("D:/Amara/Actuary/Departemen/TUGAS AKHIR/Data/Data BPR.xlsx")
Data_BPRS <- read_excel("D:/Amara/Actuary/Departemen/TUGAS AKHIR/Data/Data
BPRS.xlsx")

#Statistika Deskriptif
summary(Data_BPR)
summary(Data_BPRS)

#Visualisasi Histogram
par(mfrow = c(1, 2))
#NPL
hist_npl.bpr<-hist(Data_BPR$NPL, breaks=10, plot=F)
npl.bpr_color<-ifelse(hist_npl.bpr$breaks < 5,"steelblue","tomato")
plot(hist_npl.bpr,col=npl.bpr_color,border=F, main="(a)",
      xlab="",ylab="Frekuensi",
      xlim=c(0,50), ylim=c(0,30))

hist_npl.bprs<-hist(Data_BPRS$NPF, breaks=10, plot=F)
npl.bprs_color<-ifelse(hist_npl.bprs$breaks < 5,"steelblue","tomato")
plot(hist_npl.bprs,col=npl.bprs_color,border=F, main="(b)",
      xlab="",ylab="Frekuensi",
      xlim=c(0,50), ylim=c(0,2))

df_bpr<-as.matrix(Data_BPR[,2:7])
df_bprs<-as.matrix(Data_BPRS[,2:7])

#Z-score Standardization
sc_df_bpr<-as.matrix(scale(Data_BPR[,2:7]))
sc_df_bprs<-as.matrix(scale(Data_BPRS[,2:7]))
```

### b) Menghitung nilai VIF

```
#Mengecek Multikolinearitas
CekVIF <- function(data) {
  corr = as.matrix(cor(data))
  VIF = diag(solve(corr))

  return(VIF)
}

CekVIF(Data_BPR[,2:7])

CekVIF(Data_BPRS[,2:7])
CekVIF(Data_BPRS[,c(2,3,5,6,7)])
CekVIF(Data_BPRS[,c(2,3,6,7)])
```

## Lampiran 7 Script Analisis Clustering

### a) K-means clustering

```
#KMeans Clustering
library(tidyverse)
library(cluster)
library(factoextra)
library(dplyr)
library(cluster)
library(clusterCrit)
library(clusterSim)
#KMEANS=3
set.seed(98)
km3a<-kmeans(df_bpr, 3, iter.max=100,
             nstart=10)
set.seed(98)
km3b<-kmeans(sc_df_bpr, 3, iter.max=100,
             nstart=10)
print(km3b)
#Sil Score
sil.km3a <- silhouette(km3a$cluster, dist(df_bpr))
mean_sil.km3a <- mean(sil.km3a[, 3])
print(paste("Silhouette Score Kmeans=3 Tanpa Normalisasi:", round(mean_sil.km3a, 4)))
#DB & CH Index
idx.km3a<- intCriteria(as.matrix(df_bpr), as.integer(km3a$cluster),
                      c("Davies_Bouldin", "Calinski_Harabasz"))
print(paste("Davies-Bouldin Index Kmeans=3 Tanpa Normalisasi:",
            round(idx.km3a$davies_bouldin, 4)))
print(paste("Calinski-Harabasz Index Kmeans=3 Tanpa Normalisasi:",
            round(idx.km3a$calinski_harabasz, 4)))
#Sil Score
sil.km3b <- silhouette(km3b$cluster, dist(sc_df_bpr))
mean_sil.km3b <- mean(sil.km3b[, 3])
print(paste("Silhouette Score Kmeans=3 Dengan Normalisasi:", round(mean_sil.km3b, 4)))
#DB & CH Index
idx.km3b<- intCriteria(as.matrix(sc_df_bpr), as.integer(km3b$cluster),
                      c("Davies_Bouldin", "Calinski_Harabasz"))
print(paste("Davies-Bouldin Index Kmeans=3 Dengan Normalisasi:",
            round(idx.km3b$davies_bouldin, 4)))
print(paste("Calinski-Harabasz Index Kmeans=3 Dengan Normalisasi:",
            round(idx.km3b$calinski_harabasz, 4)))
```

## Lampiran 7 Script Analisis Clustering (Lanjutan)

### b) Fuzzy C-Means Clustering

```
#FCM Clustering
library(ppclust)
library(fclust)

#FUZZY C=3
set.seed(98)
fcm3a<-fcm(df_bpr, centers=3, m=2,
           iter.max=100, con.val=0.00001,
           stand=FALSE, numseed=98,
           dmetric = "sqeuclidean")
set.seed(98)
fcm3b<-fcm(sc_df_bpr, centers=3, m=2,
           iter.max=100, con.val=0.00001,
           stand=FALSE, numseed=98,
           dmetric = "sqeuclidean")
summary(fcm3b)

#Plot
cluster::clusplot(df_bpr, fcm3a$cluster, main="", color=TRUE, labels=0, lines=0, cex=1)
cluster::clusplot(df_bpr, fcm3b$cluster, main="", color=TRUE, labels=0, lines=0, cex=1)

#Evaluasi Klaster
# Fuzzy Silhouette Score
sil.fcm3a <- SIL.F(df_bpr,fcm3a$u, alpha=1)
paste("Fuzzy Silhouette Index: ", round(sil.fcm3a, 4))

#DB Index
db.fcm3a<-index.DB(df_bpr, fcm3a$cluster, centrotypes="centroids", p=2, q=1)
round(db.fcm3a$DB,4)

#CH Index
ch.fcm3a<-index.G1(df_bpr, fcm3a$cluster, centrotypes="centroids")
round(ch.fcm3a,4)

# Fuzzy Silhouette Score
sil.fcm3b <- SIL.F(sc_df_bpr,fcm3b$u, alpha=1)
paste("Fuzzy Silhouette Index: ",round(sil.fcm3b,4))

#DB Index
db.fcm3b<-index.DB(sc_df_bpr, fcm3b$cluster, centrotypes="centroids", p=2, q=1)
round(db.fcm3b$DB,4)

#CH Index
ch.fcm3b<-index.G1(sc_df_bpr, fcm3b$cluster, centrotypes="centroids")
round(ch.fcm3b,4)
```

## Lampiran 7 Script Analisis Clustering (Lanjutan)

### c) SOM Clustering

```
#SOM=3
set.seed(98)
som3.grid<-somgrid(xdim=1, ydim=3, topo="hexagonal",
  neighbourhood.fct ="gaussian" )
set.seed(98)
som3a.model<-som(df_bpr,
  grid=som3.grid,
  alpha=c(0.9,0.9),
  radius=0.5,
  rlen=200,
  keep.data=TRUE,
  dist.fcts="euclidean")
set.seed(98)
som3b.model<-som(sc_df_bpr,
  grid=som3.grid,
  alpha=c(0.9,0.9),
  radius=0.5,
  rlen=200,
  keep.data=TRUE,
  dist.fcts="euclidean")
#Hasil Pengelompokkan Kluster
cluster.som3a<-som3a.model$unit.classif
cluster.som3b<-som3b.model$unit.classif
cbind(cluster.som3a,cluster.som3b)

#Sil Score
sil.som3a <- silhouette(cluster.som3a, dist(df_bpr))
mean_sil.som3a <- mean(sil.som3a[, 3])
print(paste("Silhouette Score SOM=3 Tanpa Normalisasi:", round(mean_sil.som3a, 4)))
#DB & CH Index
idx.som3a<- intCriteria(as.matrix(df_bpr), as.integer(cluster.som3a),
  c("Davies_Bouldin", "Calinski_Harabasz"))
print(paste("Davies-Bouldin Index SOM=3 Tanpa Normalisasi:", round(idx.som3a$davies_bouldin,
  4)))
print(paste("Calinski-Harabasz Index SOM=3 Tanpa Normalisasi:",
  round(idx.som3a$calinski_harabasz, 4)))

#Sil Score
sil.som3b <- silhouette(cluster.som3b, dist(sc_df_bpr))
mean_sil.som3b <- mean(sil.som3b[, 3])
print(paste("Silhouette Score SOM=3 Dengan Normalisasi:", round(mean_sil.som3b, 4)))
#DB & CH Index
idx.som3b<- intCriteria(as.matrix(sc_df_bpr), as.integer(cluster.som3b),
  c("Davies_Bouldin", "Calinski_Harabasz"))
print(paste("Davies-Bouldin Index SOM=3 Dengan Normalisasi:",
  round(idx.som3b$davies_bouldin, 4)))
print(paste("Calinski-Harabasz Index SOM=3 Dengan Normalisasi:",
  round(idx.som3b$calinski_harabasz, 4)))
```

## Lampiran 8 *Script* Interpretasi Hasil Klasterisasi

```
#BoxPlot
bpr_cluster<- as.data.frame(cbind(Data_BPR[,2:7],Klaster = fcm3a$cluster))
head(bpr_cluster)

str(bpr_cluster)

boxplot(bpr_cluster$NPL~bpr_cluster$Klaster,
        col=c("lightblue","lightgreen"),
        xlab="Klaster", ylab = "NPL",
        ylim = c(-5, 50))

boxplot(bpr_cluster$LDR~bpr_cluster$Klaster,
        col=c("lightblue","lightgreen"),
        xlab="Klaster", ylab = "LDR")

boxplot(bpr_cluster$BOPO~bpr_cluster$Klaster,
        col=c("lightblue","lightgreen"),
        xlab="Klaster", ylab = "BOPO",
        ylim = c(-5, 200))

boxplot(bpr_cluster$ROA~bpr_cluster$Klaster,
        col=c("lightblue","lightgreen"),
        xlab="Klaster", ylab = "ROA",
        ylim = c(-15, 20))

boxplot(bpr_cluster$NIM~bpr_cluster$Klaster,
        col=c("lightblue","lightgreen"),
        xlab="Klaster", ylab = "NIM",
        ylim = c(-5, 50))

boxplot(bpr_cluster$KPMM~bpr_cluster$Klaster,
        col=c("lightblue","lightgreen"),
        xlab="Klaster", ylab = "KPMM",
        ylim = c(-5, 500))
```



Lampiran 9 Surat Pernyataan Data Sekunder

**SURAT PERNYATAAN**

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Aktuaria FSAD-ITS:

Nama : Amara Sabhinaya Kawiyanto

NRP : 5006211098

menyatakan bahwa data yang digunakan dalam Tugas Akhir ini merupakan data sekunder yang diambil dari *website* yaitu:

Nama Instansi : Otoritas Jasa Keuangan

Judul : Laporan Publikasi Perbankan BPR Konvensional dan BPR Syariah

URL : <https://cfs.ojk.go.id/cfs/>

Surat pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai dengan ketentuan yang berlaku.

Surabaya, July 2025

Mengetahui,  
Dosen Pembimbing Tugas Akhir



Prilyandari Dina Saputri, S.Si., M.Stat.  
NIP. 19950404 202406 2 001

Mahasiswa



Amara Sabhinaya Kawiyanto  
NRP. 5006211098



## BIODATA PENULIS



Penulis dilahirkan di Semarang pada tanggal 16 April 2003, dan merupakan anak pertama dari 2 bersaudara. Penulis telah menempuh pendidikan formal mulai dari SD Gayamsari 02 Semarang, SMPN 2 Semarang, dan SMAN 2 Semarang. Setelah lulus dari SMA, penulis berkuliah di Departemen Aktuaria, Institut Teknologi Sepuluh Nopember Surabaya, dan terdaftar dengan nomor registrasi peserta (NRP) 5006211098. Selama masa perkuliahan penulis aktif pada beberapa kegiatan non-akademik. Kegiatan non-akademik yang pernah dilakukan penulis diantaranya, organisasi, kepanitiaan, kerja praktik, dan magang. Organisasi yang pernah diikuti penulis diantaranya adalah Kepemanduan FSAD, komunitas *Save Street Child* Surabaya (SSCS), dan Komunitas Rumah Sandar. Kepanitiaan yang pernah diikuti penulis antara lain, GERIGI ITS 2023, Ini Lho ITS! 2022 dan 2023, Aksi Nirwasita FSAD, dan Jelajah Aktuaria 2022. Penulis pernah melakukan KP di PT. BPR Jateng. Penulis juga pernah melaksanakan magang di Badan Pusat Statistik (BPS) Kota Surabaya. Selain itu, penulis juga memiliki pengalaman bekerja paruh waktu sebagai tutor privat jenjang SD dan SMP. Adapun informasi lebih lanjut mengenai tugas akhir ini, dapat ditanyakan kepada penulis melalui email [amara.naya16@gmail.com](mailto:amara.naya16@gmail.com) atau LinkedIn penulis pada laman <https://www.linkedin.com/in/amarasabhinaya>.