

## BAB 2 LANDASAN KEPUSTAKAAN

### 2.1 Kajian Pustaka

Pada sub bab ini membahas terkait penelitian terdahulu yang pernah dilakukan oleh Atranto et al. (2011) yang berjudul “*Customer Profiling dengan Menggunakan K-Means Clustering untuk Mendukung Pengambilan Keputusan Strategis di PT Pelabuhan Indonesia III (PERSERO)*”. Pada penelitian tersebut membahas tentang mengkategorikan pengguna jasa berdasarkan hasil *customer profiling* menggunakan *K-Means clustering* dan model RFM dengan atribut tambahan. Tahapan yang digunakan untuk pengolahan data dan implementasi terdiri dari *preprocessing data*, uji korelasi data menggunakan SPSS 17, dan *clustering data* dengan metode *K-Means clustering* menggunakan tools *RapidMiner*. Sedangkan uji coba dan analisis hasil *K-Means clustering* menggunakan sejumlah skenario, diantaranya variasi jumlah *cluster* dan atribut. Kemudian dianalisis pencarian *cluster* yang optimal dan karakteristik pelanggan dengan menggunakan *DBIndex*, *distance-between*, dan *distance-within*. Kemudian dilakukan *cross-analysis* sebagai metode dalam penambahan atribut status pembayaran. Berdasarkan nilai *DB-index* dan *distance-within* yang relatif kecil sedangkan *distance between* yang relatif besar dibanding model *clustering* lainnya, maka hasil *clustering* optimal adalah 2 cluster. Jika ditinjau dari perspektif manajerial, maka pengelompokan ke dalam 4 *cluster* lebih menggambarkan karakteristik pelanggan dibanding 2 atau 3 *cluster*. Hal tersebut karena ditunjang dengan adanya karakteristik waktu operasional yang efisien dan tingkat pelunasan pembayaran pelanggan.

Penelitian selanjutnya dilakukan oleh Angelie (2017) yang berjudul “*Segmentasi Pelanggan Menggunakan Clustering K-Means dan Model RFM (Studi Kasus: PT. Bina Adidaya Surabaya)*”. Pada penelitian tersebut membahas tentang masalah belum pernah dilakukannya analisis perilaku *retailer* dalam proses transaksi, sehingga perusahaan masih memberikan strategi layanan yang sama kepada semua *retailer*. Maka dari masalah tersebut diperlukan pembuatan segmen pelanggan (*retailer*) PT. Bina Adidaya dan mendeskripsikan karakteristik setiap segmen berdasarkan informasi pada hasil *clustering* dengan model RFM. Metode yang dilakukan untuk segmentasi pelanggan yakni *K-Means Clustering*. Menurut penelitian ini, metode *K-Means clustering* merupakan metode paling optimum. Normalisasi parameter RFM dengan Min- Max dan

penentuan CLV berdasarkan hasil metode AHP. Hasil penerapan metode *K-Means clustering* telah diuji performa menggunakan *Dunn Index* dan *Connectivity*. Hasil penentuan jumlah *cluster* berdasarkan metode *Elbow* menentukan jumlah *cluster* menjadi 3, meskipun masih terdapat nilai variabel yang *overlapping* tetapi penentuan jumlah cluster ini dapat memisahkan kelompok *retailer* yang tergolong masih aktif dan cenderung memiliki nilai *recency*, *frequency*, dan *monetary* yang lebih unggul dari kelompok lain. Karakteristik yang terbentuk dari pembagian menjadi 3 segmen yaitu *cluster 1* dinilai mampu memberikan kontribusi keuntungan yang sangat besar di masa depan. Kontribusi yang diberikan *retailer* pada *cluster 2* tidak terlalu besar dibandingkan dengan *cluster 1*, akan tetapi perusahaan perlu membuat strategi yang dapat menjadikan *cluster 2* untuk cenderung naik dalam memberikan kontribusi keuntungan. Sedangkan *retailer* yang termasuk dalam *cluster 3* memberikan kontribusi yang sangat sedikit untuk perusahaan, sehingga *cluster 3* merupakan *retailer* yang paling terakhir menjadi prioritas pelayanan atau bahkan menjadi *retailer* yang tidak perlu diperhatikan lebih oleh perusahaan.

Dari beberapa penelitian tersebut, pada skripsi ini membahas metode segmentasi pelanggan yang sama dengan menggunakan metode *K-Means Clustering* yang dianggap sebagai metode yang optimum. Akan tetapi yang membedakan skripsi ini dengan penelitian terdahulu yakni pada tambahan variabel layanan yang dapat dibandingkan dengan variabel RFM untuk mempertajam hasil analisis.

## 2.2 Profil Klinik Kecantikan Belle Crown Malang

*Belle Crown* merupakan salah satu klinik kecantikan yang tergolong baru di Kota Malang. Klinik kecantikan yang beralamatkan di Jalan Bukit Barisan No. 7 ini memiliki desain tempat dengan nuansa yang cukup mewah namun harga terjangkau. *Belle Crown* menghadirkan paket layanan untuk membentuk sebuah *charm standard a woman*, yakni berupa ketenangan suasana, keunggulan produk, dan kemampuan status social. Di *Belle Crown* terdapat segala fasilitas yang dibutuhkan wanita seperti salon untuk perawatan rambut dan wajah, serta perawatan kulit dengan *spa*. Jasa dan layanan yang ditawarkan oleh *Belle Crown* diantaranya :

1. Fasilitas *creambath*, *smoothing reboinding*, *hair spa*, *hair mask*, *hair cut*, *styling*, *cuci blow*, *coloring*, *toning*, *hair manicure*, *hair glossy*, keriting, dan permintaan konsumen lainnya yang dapat dikerjakan.

2. Terdapat refleksi *manicure, pedicure* dan *geh wol*.
3. Terdapat *therapeutic skin care* yang meliputi *facial* dan totok wajah, *skin rejuvination, microdermabrasion*, dan *acne peeling*.
4. Terdapat *spa* dan *body treatment* seperti lulur mandi rempah, masker *whitening*, mandi susu, *body massage whitening*, ratus V.
5. Memiliki jenis produk dan obat buatan *Belle Crown* untuk mengatasi berbagai masalah pada kulit maupun wajah dan juga produk lainnya untuk rambut.
6. Terdapat *pool and gym* untuk menjaga kebugaran badan.

### **2.3 Manajemen Hubungan Pelanggan (*Customer Relationship Management*)**

Konsep hubungan pelanggan mengalami perkembangan dari *relationship marketing* menjadi *Customer Relationship Management* (CRM). Kotler dan Keller (2007) menyatakan bahwa kombinasi dari proses dan teknologi yang bertujuan memahami pelanggan dalam hal perbedaan produk dan jasa yang digunakan dapat diartikan sebagai CRM. CRM memungkinkan pemberian layanan yang unggul pada pelanggan berdasarkan penggunaan informasi yang efektif dari pelanggan.

Menurut Kotler dan Keller (2007), terdapat empat aktivitas CRM yaitu :

1. Mengidentifikasi (*identify*)

Aktivitas pertama dalam penerapan CRM, diantaranya mengetahui karakteristik pelanggan, mengetahui pelanggan potensial dan sebaliknya, identifikasi sistem internal yang diperlukan terkait pelanggan. Dengan kegiatan identifikasi, suatu perusahaan dapat mengenali pelanggan dan menjalin relasi secara personal guna menemukan pelanggan potensial.

2. Mengakuisisi (*acquire*)

Setelah proses identifikasi, selanjutnya perlu dilakukan proses akuisisi pelanggan secara efektif dan efisien. Hal tersebut dapat dilakukan dengan cara mengkategorikan atau memberi peringkat pada setiap pelanggan berdasarkan kontribusi yang

diberikan pada perusahaan. Sehingga pelanggan akan mendapatkan perlakuan sesuai dengan kebutuhan dan kontribusinya pada perusahaan.

3. Mempertahankan (*retain*)

Aktivitas lanjutan setelah akuisisi pelanggan yakni menjaga kesetiaan pelanggan agar tidak berpaling pada produk yang bersaing. Berberapa hal dapat dilakukan untuk mempertahankan pelanggan, seperti pemberian *reward* pada pelanggan potensial, memberikan pelayanan yang profesional dan menjalin relasi jangka panjang pada pelanggan.

4. Mengembangkan (*develop*)

Melalui data informasi pelanggan, perusahaan dapat memahami kebutuhan pelanggan. Informasi ini dapat diolah sebagai nilai tambah agar mencapai keunggulan kompetitif.

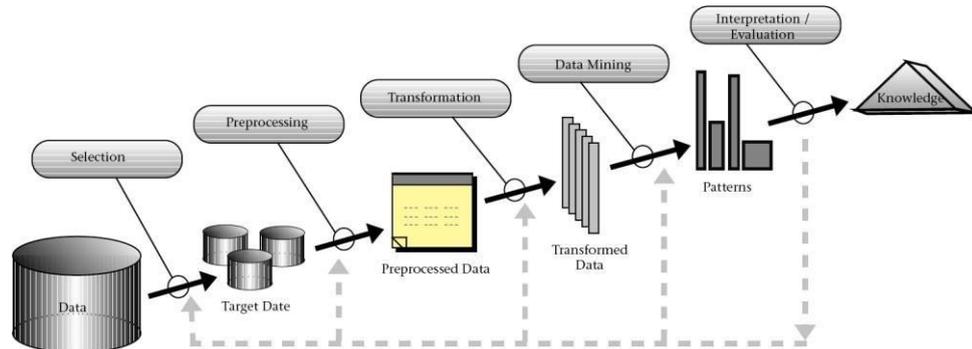
Penerapan CRM yang memenuhi aktivitas-aktivitas tersebut dinilai berhasil karena mampu mengenali pelanggan secara personal dengan memberikan layanan sesuai kebutuhan. Jika kebutuhan pelanggan terpenuhi, maka retensi pelanggan dapat dipertahankan dengan melakukan pembelian ulang. Sehingga perusahaan mendapatkan profit yang tinggi dari pelanggan.

## **2.4 Knowledge Discovery in Database (KDD) dan Data Mining**

### **2.4.1 Knowledge Discovery in Database (KDD)**

Sekumpulan data dengan jumlah yang besar dapat digali informasinya dengan istilah *data mining* dan *Knowledge Discovery in Databases* (KDD) Kedua istilah tersebut memiliki pengertian yang berbeda namun memiliki keterkaitan. Menurut Han dan Kamber (2006) menyatakan bahwa proses *data mining* merupakan bagian tahapan dalam proses KDD.

Berikut adalah tahapan dalam proses KDD pada Gambar 2.1:



**Gambar 2.1 Tahapan KDD**

Sumber : Han dan Kamber (2006)

Penjelasan terkait tahapan KDD, diantaranya:

*a. Data Selection*

Pada tahapan ini dilakukan proses pemilihan data target. Hasil pemilihan tersebut kemudian disimpan secara terpisah dari data aslinya.

*b. Pre-Processing dan Cleaning Data*

Pada *pre processing data* dan *data cleansing*, dilakukan beberapa proses yakni penghapusan data yang tidak konsisten, duplikasi data, *noise*, ataupun memperbaiki data yang salah..

*c. Transformation*

Pada tahap ini dilakukan proses penggabungan data dengan cara agregasi.

*d. Data Mining*

Proses menemukan suatu pola dari data dengan suatu metode tertentu sesuai tujuan.

*e. Interpretation atau Evaluasi*

Pada tahapan ini terjadi proses penerjemahan pola yang telah dihasilkan dari proses *data mining*. Hasil tersebut kemudian dievaluasi dan divisualisasikan.

## 2.4.2 Data Mining

### 1. Pengertian Data Mining

Santosa (2007) menyatakan bahwa kegiatan mengumpulkan dan

menggunakan data historis dalam menemukan suatu pola atau relasi dalam skala besar dapat disebut dengan *data mining*. Salah satu aktivitas utama *data mining* adalah teknik *clustering* terhadap data yang sebenarnya.

Sedangkan Larose dan Daniel (2005) menyatakan bahwa *data mining* adalah menggunakan teknologi seperti teknik statistic dan matematis untuk menyimpan data berukuran besar melalui proses menemukan korelasi, pola dan tren baru.

## **2. Tujuan Data Mining**

Baskoro (2010) menyatakan bahwa terdapat tiga tujuan *data mining* yakni :

- a. *Explanatory*, yaitu penjelasan terkait kegiatan penelitian.
- b. *Confirmatory*, yaitu melakukan konfirmasi terkait hipotesis yang ada.
- c. *Exploratory*, yaitu menganalisis relasi pada data baru.

## **3. Pengelompokan Data Mining**

Tan et. al. (2005), menyatakan bahwa terdapat dua kategori utama dalam *data mining*, yaitu :

- a. *Descriptive mining*, yaitu proses menentukan karakteristik dari data. Teknik yang termasuk dalam kategori ini adalah *sequential mining, clustering, association*.
- b. *Predictive mining*, yaitu penggunaan beberapa variable lain guna mendapatkan pola dari data. Salah satu teknik nya yakni klasifikasi.

Larose dan Daniel (2005), menyatakan bahwa *data mining* dikelompokkan berdasarkan tugas sebagai berikut :

- a. Deskripsi  
Penjelasan dari penggambaran pola dari data.
- b. Estimasi  
Pngertiannya mirip dengan klasifikasi. Variabelnya bersifat numerik.
- c. Prediksi  
Pngertiannya mirip dengan klasifikasi dan estimasi, hanya saja nilainya akan terwujud di masa

mendatang.

d. Klasifikasi

Klasifikasi adalah proses menemukan pola gambaran kelas data yang berbeda dan bertujuan menentukan kelas untuk suatu data (Han and Kamber, 2006).

e. *Clustering*

*Clustering* adalah proses mengelompokkan suatu objek ke dalam kelas objek yang memiliki karakteristik yang sama. (Han & Kamber, 2006).

f. Asosiasi

Menemukan kemunculan atribut dalam satu waktu.

## 2.5 Analisis RFM (*Recency, Frequency, Monetary*)

Analisis RFM merupakan proses analisis perilaku pelanggan. Proses ini biasanya digunakan dalam pemasaran *database* dan pemasaran langsung. Untuk menentukan segmentasi pelanggan maka digunakan model RFM berdasarkan tiga variabel yaitu *Recency of the last purchases*, *Frequency of the purchases*, dan *Monetary value of the purchases*.

Menurut Tsiptsis dan Chorianopoulos (2009), analisis RFM terdiri dari tiga variabel yaitu *Recency, Frequency, Monetary*.

1. *Resensi*

*Recency* adalah mengukur nilai pelanggan dengan melihat rentang waktu (tanggal, bulan, maupun tahun) dari transaksi terakhir pelanggan sampai saat ini. Semakin kecil rentangnya, maka nilai R semakin besar.

2. *Frequency*

*Frequency* adalah mengukur nilai pelanggan dengan melihat jumlah total atau rata-rata transaksi dalam satu periode. Semakin banyak *frequency*, maka nilai F semakin besar.

3. *Monetary*

*Monetary* adalah mengukur nilai pelanggan dengan melihat jumlah rata-rata transaksi pelanggan dalam satu periode. Semakin banyak jumlah besaran uang yang dikeluarkan pelanggan pada periode tersebut maka nilai M semakin besar.

Menurut Cheng dan Chen (2009), semakin besar nilai  $R$  dan  $F$  maka kemungkinan pelanggan akan melakukan transaksi kembali dengan perusahaan tersebut. Selain itu semakin besar nilai  $M$ , maka kecenderungan pelanggan dalam memberikan respon kepada produk dan layanan perusahaan tersebut.

## 2.6 Normalisasi *Min-Max*

Normalisasi dilakukan dengan menyesuaikan parameter RFM yang telah dibuat (Khajvand dan Tarokh, 2011). Metode ini merupakan metode normalisasi dengan cara melakukan transformasi atribut numerik dalam skala yang lebih kecil yaitu dengan batas terendah 0.0 dan batas tertinggi 1.0 (Junaedi dkk., 2011). Berikut adalah persamaan normalisasi *Min-Max* pada persamaan (2.1).

$$x' = \frac{x - \min_a}{\max_a - \min_a} (\text{newmax} - \text{newmin}) + \text{newmin} \dots (2.1)$$

Sumber : Dewi dkk. (2013)

Dimana:

$x'$  = nilai setelah dinormalisasi

$x$  = nilai asli yang akan dinormalisasi

$\min_a$  = nilai minimal setiap variabel.

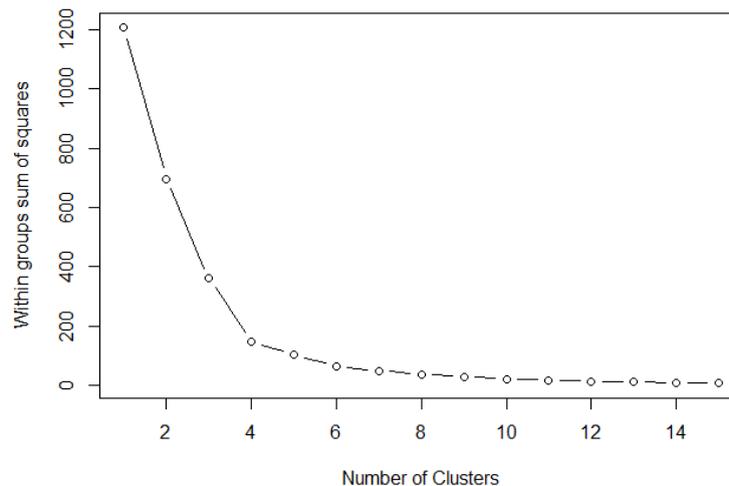
$\max_a$  = nilai maksimal setiap variable.

$\text{newmax}$  = rentang maksimal  $x$  dengan nilai 1.

$\text{newmin}$  = rentang manimal  $x$  dengan nilai 0.

## 2.7 Metode *Elbow*

Menurut Bholowalia dan Kumar (2014), metode *Elbow* adalah metode yang digunakan dalam analsis *cluster* untuk interpretasi dan uji performa tingkat konsistensi jumlah *cluster* yang tepat dengan melihat nilai SSE (*Sum Square of Error*) . Pada titik tertentu akan terjadi grafik penurunan secara dramatis dengan sebuah lekukan yang disebut dengan kriteria siku. Nilai itu kemudian menjadi nilai  $k$  atau jumlah *cluster* yang terbaik (Bholowalia dan Kumar, 2014). Berikut adalah gambaran dari grafik pada metode *Elbow* pada Gambar 2.2.



**Gambar 2.2 Grafik Metode Elbow**

Metode ini dimulai dengan menentukan nilai  $k = 2$ , kemudian di-*increment*. Lalu dihitung nilai SSE-nya. Pada titik tertentu, SSE akan mengalami penurunan secara dramatis, lalu mencapai titik konstan. Menurut Bholowalia dan Kumar (2014), algoritma metode *Elbow* dijelaskan pada Tabel 2.1.

**Tabel 2.1 Algoritma Metode *Elbow***

<b>Algoritma : Metode elbow untuk menentukan nilai k dari Kmeans</b>	
1	Inisialisasi $k=1$
2	<i>Start</i>
3	<i>Increment</i> nilai $k$
4	Hitung SSE
5	Pada titik tertentu nilai SSE akan turun drastis
6	nilai $k$
7	<i>End</i>

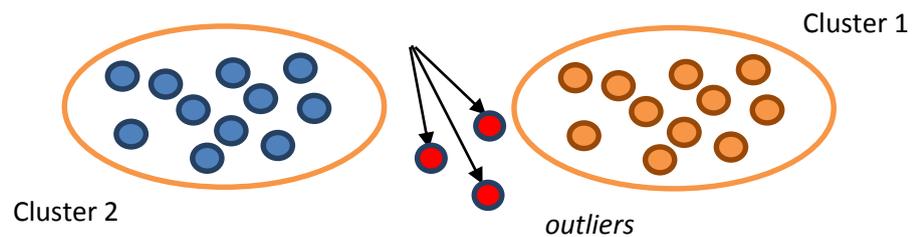
## 2.8 Clustering

### 2.8.1 Pengertian Clustering

Menurut Han dan Kamber (2006), proses mengelompokkan suatu objek ke dalam kelas objek yang memiliki karakteristik yang sama. Sedangkan Baskoro (2010) menyatakan bahwa *clustering* adalah salah satu teknik *data mining* dalam mengelompokkan objek dengan tingkat *similarity* yang tinggi ke dalam satu *cluster* dan *dissimilar* terhadap objek yang berbeda *cluster*. Sehingga objek dalam satu *cluster* memiliki kesamaan atau kemiripan yang

tinggi. Objek-objek tersebut mengalami pengelompokan dengan prinsip memaksimalkan *similarity* dan memaksimalkan *dissimilarity* antar *cluster*.

Diharapkan dengan penggunaan *clustering*, maka ditemukan daerah padat, ditemukannya pola distribusi keseluruhan, dan hubungan antar atribut data. Fokus dari *data mining* adalah efektivitas dan efisiensi metode dalam menentukan *cluster* pada data berukuran besar. Berikut adalah contoh *clustering* pada Gambar 2.3.



**Gambar 2.3 Contoh Clustering**

Sumber : Baskoro, 2010

### 2.8.2 Metode Clustering

Terdapat beberapa metode *clustering* yang dapat digunakan dengan meninjau tipe data dan tujuan *clustering*. Menurut Baskoro (2010) metode-metode tersebut meliputi :

a. *Partitioning Method*

Membuat partisi dan mengevaluasinya. Seperti algoritma PROCLUS, K-Means, CLARA, CLARANS, K-Medoid, dan PAM.

b. *Hierarchical Methods*

Menguraikan sekumpulan data dengan beberapa kriteria. Seperti yang termasuk metode ini yakni algoritma AGNES, CURE, BIRCH, CHAMELEON, DIANA.

c. *Density-based Methods*

Metode ini berdasarkan hubungan dan fungsi densitas, seperti algoritma DENCLU, OPTICS, DBSCAN.

d. *Grid-based Methods*

Metode ini berdasarkan struktur granularitas multi-level, seperti algoritma STING, WaveCluster, dan CLIQUE.

e. *Model-based Methods*

Menghipotesakan model untuk masing-masing *cluster* dan mencari kecocokan untuk *cluster* yang lain, seperti algoritma COBWEB dan SOM.

Sadaaki et. al. (2008) menyatakan bahwa ada dua pendekatan yang padat digunakan sebelum menentukan jumlah *cluster*, yaitu :

- a. *supervised* atau jumlah *cluster* telah ditentukan.
- b. *unsupervised* atau jumlah *cluster* tidak ditentukan.

## **2.9 Teorema *K-Means Clustering***

### **2.9.1 *K-Means Clustering***

*K-Means* adalah suatu algoritma dengan mengelompokkan suatu objek dengan karakteristik yang sama ke dalam suatu *cluster* yang telah ditentukan nilai  $k$  nya secara iteratif. *K-Means* merupakan algoritma yang umum dan mudah serta mampu beradaptasi dalam pengimplementasiannya. Secara historis, *K-Means* merupakan algoritma terpenting dalam *data mining* (Wu dan Kumar, 2009).

### **2.9.2 Langkah *K-Means Clustering***

Secara umum algoritma *K-Means* adalah sebagai berikut :

- a. Tentukan jumlah kluster  $k$ .
  - Pemberian nilai secara random.
  - Pengambilan sampel awal data.
  - Penentuan nilai awal hasil kluster hirarki dengan jumlah kluster yang sesuai dengan penentuan awal.
- b. Inisialisasi  $k$  pusat kluster.
- c. Tempatkan objek ke kluster terdekat.
  - Berdasarkan kedekatannya dengan pusat kluster.
  - Dihitung jarak tiap data ke tiap pusat kluster.
  - Jarak paling dekat tersebut akan menjadi penentu masuk kluster mana.
- d. Perhitungan kembali pusat kluster.
  - Menghitung nilai rata rata data dalam kluster tertentu.
  - Pada kasus tertentu digunakan median, karena median tidak sensitif terhadap *outlier* data.

- e. Ulangi langkah c dengan pusat *cluster* baru. Jika nilai pusat *cluster* tidak mengalami perubahan, maka proses *clustering* dihentikan.

## 2.10 Euclidian Distance

*Euclidian distance* merupakan persamaan untuk menghitung jarak antar data dengan menghitung akar perbedaan data yang berpasangan. Jarak tersebut digunakan untuk menentukan *cluster* dari anggota pada proses *K-Means Clustering* (Singh dkk., 2013). Berikut adalah persamaan *Euclidean Distance* menurut Singh dkk. (2013) pada persamaan (2.2).

$$dist((x, y), (a, b)) = \sqrt{(x - a)^2 + (y - b)^2} \dots (2.2)$$

Dimana :

$Dist()$  = *Euclidean Distance*

$(x, y)$  = koordinat data

$(a, b)$  = koordinat centroid.

Kelebihan *euclidean distance* salah satunya adalah memberikan hasil yang optimal pada sekumpulan data terpisah (Singh dkk., 2013).

## 2.11 Sum of Square Error (SSE)

SSE merupakan metode yang banyak digunakan untuk mengevaluasi pengelompokan, karena SSE berfungsi mengukur tingkat keseragaman data dalam satu *cluster*. Semakin kecil nilai SSE, maka hasil *clustering* dinilai semakin bagus. Berikut persamaan untuk mencari SSE menurut Tan dkk. (2005) pada persamaan (2.3).

$$SSE = \sum_{i=1}^k \sum_{x \in C_i} dist^2(m_i, x) \dots (2.3)$$

Dimana:

$k$  = jumlah *cluster* yang terbentuk.

$C_i$  = *cluster* ke- $i$ .

$m_i$  = *cluster* ke- $i$ .

$x$  = data setiap *cluster*.

## 2.12 Dunn Index

*Dunn Index* merupakan metrik untuk memvalidasi hasil pengelompokan dengan mengukur diameter *cluster* dan jarak antara dua *cluster*. Dengan mengukur *Dunn Index* dapat diketahui jumlah *cluster* yang optimum (Khajvand dan Tarokh, 2011). *Dunn Index* dihitung dengan mengukur rasio jarak terbesar antar *cluster* dengan jarak terkecil di dalam *cluster* (Bhatia, 2012). Berikut adalah persamaan *Dunn Index* menurut Saitta dkk. (2007) pada persamaan (2.4).

$$DU = \min_{\substack{i=1, \dots, k \\ j=i+1, \dots, k}} \left( \frac{\text{diss}(c_i, c_j)}{\max_{m=1, \dots, k}(\text{diam}(c_m))} \right) \dots (2.4)$$

Dimana:

$DU$  = Dunn Index.

$k$  = jumlah *cluster*.

$(c_i, c_j)$  = jarak *cluster*  $i$  dan *cluster*  $j$ .

$\text{diam}(c_m)$  = diameter *cluster*  $i$ .

*Dunn Index* akan melakukan pengecekan terhadap kesesuaian *cluster*, varian antar *cluster*, dan penilaian untuk *cluster* tertentu. Semakin tinggi nilai *Dunn Index*, maka semakin optimal jumlah *cluster* (Fluegemann dkk., 2011).

## 2.13 Silhoutte Width

*Silhouette* dapat diartikan mengukur derajat kepercayaan peletakkan objek ke dalam suatu *cluster* dalam *clustering*. *Silhouette width* merupakan hasil rata-rata dari nilai *Silhouette* setiap observasi. *Silhouette* mengukur derajat kepercayaan penempatan dalam *clustering*, jika nilai *Silhouette* mendekati 1 maka penempatan *cluster* sudah sesuai, akan tetapi jika nilainya mendekati -1 maka penempatannya tidak sesuai dan harus diminimalkan (Brock dkk., 2011). Berikut persamaan untuk mencari *Silhouette Width* menurut Brock dkk. (2011) pada persamaan (2.5).

$$S(i) = \frac{b_i - a_i}{\max(b_i, a_i)} \dots (2.5)$$

Dimana :

$a_i$  = rata-rata jarak  $i$  dengan objek lain dalam satu *cluster*.

$b_i$  = rata-rata jarak  $i$  dengan objek pada *cluster* terdekat.

## 2.14 Connectivity

Metode *Connectivity* merepresentasikan kekuatan hubungan antar anggota *cluster*. Nilai *Connectivity* memiliki rentang antara nol dan  $\infty$ . Semakin rendah nilai *Connectivity*, maka jumlah *cluster* semakin optimal (Brock dkk., 2011). Berikut adalah persamaan *Connectivity* menurut Brock dkk. (2011) pada persamaan (2.6).

$$Conn = \sum_{i=1}^N \sum_{j=1}^L x_{i,nni(j)} \dots (2.6)$$

Dimana :

$nni(j)$  = tetangga terdekat dari  $j$  dari pengamatan di  $i$ .

$x_{i,nni(j)}$  = mendekati nol jika  $i$  dan  $j$  dalam satu *cluster* dan 1 jika sebaliknya.

$L$  = parameter yang menentukan jumlah tetangga yang berkontribusi terhadap indeks konektivitas.

## 2.15 Konsep Dasar Dashboard

### 2.15.1 Definisi Dashboard

Malik (2005) menggunakan istilah *enterprise dashboard*, yaitu antar muka dalam pengelolaan inisiatif bisnis dengan memvisualisasikan secara dinamis terkait bagan, *report*, indicator visual, dan mekanisme peringatan.

Few (2006) menggunakan istilah *information dashboard*, yaitu sebagai visualisasi informasi yang dibutuhkan untuk mencapai tujuan tertentu dengan menggabungkan informasi ke dalam satu layar.

Orts (2005) menggunakan istilah *dashboard*, yaitu alat *monitoring* organisasi dari waktu ke waktu dengan menampilkan informasi dalam suatu *user interface*, sehingga manajer dapat mengakses pihak pengambil keputusan dapat mengakses informasi kinerja bisnis secara aktif.

Eckerson (2005) menggunakan istilah *dashboard* yaitu mekanisme visualisasi informasi dalam sistem manajemen kinerja, yang menyajikan informasi kinerja operasional.

Berdasarkan penjelasan tersebut, istilah-istilah tersebut memiliki pengertian yang sama, yaitu menampilkan visualisasi informasi ke dalam satu layar.

### 2.15.2 Tujuan Pengguna *Dashboard*

Malik (2005) menyatakan bahwa *dashboard* dimanfaatkan untuk memonitor sistem yang kompleks dan *interdependent*. Pihak manajemen suatu organisasi memerlukan informasi yang dibutuhkan guna menentukan kebijakan dan strategi untuk mendukung pencapaian tujuan organisasi. Sedangkan Eckerson (2005) menyatakan bahwa *dashboard* didesain guna pencapaian tujuan strategis suatu organisasi atau perusahaan.

Sehingga dengan penggunaan *dashboard* diharapkan dapat mengukur, memonitor, dan memprediksi suatu aktivitas baik yang telah berjalan, sedang berjalan, maupun aktivitas selanjutnya. Oleh karena itu, organisasi diharapkan dapat mengukur dan memperbaiki strategi yang ada dalam rangka memaksimalkan kinerjanya. Eckerson (2005) juga menyatakan kelebihan *dashboard* diantaranya :

1. Mengkomunikasikan strategi.

Menjadi sarana dalam menyalurkan strategi yang dibuat oleh pihak eksekutif pada seluruh pihak yang berperan.

2. Memonitor dan menyusun kembali pelaksanaan strategi

Melalui *monitoring* terhadap pelaksanaan strategi, pihak eksekutif dapat mengidentifikasi masalah kritis dan menentukan strategi sebagai solusinya.

3. Menyampaikan informasi ke semua pihak

Sebagai penyaji informasi dalam satu layar yang menggunakan bagan, grafik, simbol, dan warna yang interaktif guna mempermudah pengguna dalam memahami persepsi informasi secara tepat.