CLUSTERING NASABAH BANK MENGGUNAKAN *K-MEANS* BERDASARKAN NILAI *RFM* (*RECENCY, FREQUENCY, MONETARY*)

Oleh

KRISTIAN CHANDRA
Enterprise Information System PT. OCBC NISP, Tbk.
Jl. Asia Afrika No. 100 Bandung
Email : kristian.chandra.86@gmail.com

Abstract

The banking industry is one industry that requires a lot of information in their daily activities. Nowadays many banks no longer rely on an attractive offer, but rely on services to win the trust of customers. To be able to provide the services to the customer, the bank will also need to collect and process information about customers. Customer information is an important key in running the business strategy of the banking industry. Data Mining is a process of collecting, processing, and presentation of customer information that can be used by management as a strategy that will be used to compete with others engaged in similar industry, but it also can enhance their business performance. The Model Data Mining using variable RFM (Recency, Frequency, Monetary) on customer transactions, and then processed using K-Means algorithm for cluster each customer.

Keywords: Data Mining, Clustering, K-Means, RFM, Bank

Abstrak

Industri perbankan merupakan salah satu industri yang memerlukan banyak informasi dalam kegiatan sehari-harinya. Pada jaman sekarang ini banyak bank sudah tidak lagi mengandalkan penawaran yang menarik, tetapi mengandalkan jasa atau service untuk memenangkan kepercayaan dari nasabah. Untuk dapat memberikan jasa atau service kepada nasabah, bank juga perlu mengumpulkan dan mengolah informasi mengenai nasabah. Informasi nasabah adalah kunci yang penting dalam menjalankan strategi bisnis industri perbankan. Data Mining merupakan salah satu proses pengumpulan, pengolahan, dan penyajian informasi nasabah yang dapat digunakan oleh pihak manajemen sebagai strategi yang akan dipakai untuk bersaing dengan pihak lain yang bergerak dalam industry yang sejenis, selain itu juga teknik Data Mining digunakan untuk meningkatkan kinerja bisnis. Pemodelan Data Mining ini dilakukan dengan menggunakan variabel RFM (Recency, Frequency, Monetary) pada transaksi nasabah, kemudian diolah dengan menggunakan algoritma K-Means untuk mendapatkan Cluster setiap nasabah.

Kata Kunci : Data Mining, Clustering, K-Means, RFM, Bank

1. PENDAHULUAN

Data merupakan salah satu alat untuk memperoleh informasi, bahkan jika diolah dengan baik akan berguna bagi perusahaan. Tentu saja dengan semakin canggihnya teknologi yang berkembang selama ini, bukan tidak mungkin informasi yang pengguna butuhkan sudah tersedia ketika pengguna mengumpulkan data. Salah satu contohnya adalah *Data Warehouse*, pada *Data Warehouse* semua data yang berhubungan dengan perusahaan akan dikumpulkan disini. Seringkali data yang ada pada *Data Warehouse* tidak digunakan dengan baik, bahkan akan menjadi informasi yang sia-sia saja.

Untuk mengolah informasi atau data yang sudah pernah dikumpulkan, maka diperlukan pengolahan menggunakan *Data Mining* yang baik. Salah satu penggunaan *Data Mining* digunakan untuk menganalisa data historikal untuk menentukan pola data tersebut. Dunia perbankan merupakan salah satu industri yang cocok menggunakan *Data Mining* untuk mengolah data nasabah menjadi informasi yang berguna bagi manajemen.

PT. OCBC NISP Tbk. adalah salah satu bank dari sekian banyak bank yang ada di Indonesia dan sudah menggunakan *Data Warehouse* sebagai wadah penyimpan informasi yang terjadi di bank tersebut. Dengan adanya *Data Warehouse* ini, dapat menjadi sumber sebagai informasi yang dapat digunakan untuk keperluan *Data Mining*. Permasalahan yang muncul adalah belum adanya pengolahan informasi atau data yang berhubungan dengan *Customer Relationship*. Hal tersebut memerlukan adanya suatu pengelolaan sumber daya informasi yang didasarkan pada sebuah model, oleh karena itu penelitian ini berfokus kepada pengolahan data *Customer Relationship* menggunakan *Data Mining*. Kemudian nantinya akan menghasilkan informasi yang dapat men-segmentasi nasabah sesuai dengan pola transaksi nasabah. Diharapkan nantinya hasil penelitian ini dapat memberikan pedoman bagi pengembangan *Data Mining* di PT. OCBC NISP Tbk.

1.1. Data Mining

Data mining (penambangan data), sesuai dengan namanya, berkonotasi sebagai pencarian informasi bisnis yang berharga dari basis data yang sangat besar. Usaha pencarian yang dilakukan dapat dianalogikan dengan penambangan logam mulia dari lahan sumbernya. Dengan tersedianya basis data dalam kualitas dan ukuran yang memadai, teknologi *data mining* memiliki kemampuan-kemampuan sebagai berikut :

1. Mengotomatisasi prediksi tren dan sifat-sifat bisnis. *Data mining* mengotomatisasi proses pencarian informasi pemprediksi di dalam basis data yang besar. Pertanyaanpertanyaan yang berkaitan dengan prediksi ini dapat cepat dijawab

langsung dari data yang tersedia. Contoh dari masalah prediksi ini misalnya target pemasaran, peramalan kebangkrutan dan bentuk-bentuk kerugian lainnya.

2. Mengotomatisasi penemuan pola-pola yang tidak diketahui sebelumnya. Kakas *data mining* "menyapu" basis data, kemudian mengidentifikasi pola-pola yang sebelumnya tersembunyi dalam satu sapuan. Contoh dari penemuan pola ini adalah analisis pada data penjulan ritel untuk mengidentifikasi produk-produk, yang kelihatannya tidak berkaitan, yang seringkali dibeli secara bersamaan oleh pelanggan. Contoh lain adalah pendeteksian transaksi palsu dengan kartu kredit dan identifikasi adanya data anomali yang dapat diartikan sebagai data salah ketik (karena kesalahan operator).

Proses *Data Mining* sangat tergantung terhadap algoritma yang dipakai, mengenai hal ini (*Tang, ZhaoHui. MacLennan, Jamie. 2005 p:3)* menjelaskan :

Data mining applies algorithms, such as decision trees, clustering, association, time series, and so on, to a dataset and analyzes its contents. This analysis produces patterns, which can be explored for valuable information. Depending on the underlying algorithm, these patterns can be in the form of trees, rules, clusters, or simply a set of mathematical formulas. The information found in the patterns can be used for reporting, as a guide to marketing strategies, and, most importantly, for prediction.

Menurut *Vivek Bhambri , 2011* , Tahapan proses data *mining* dilakukan dengan cara sebagai berikut :

1. *Data Selection*

   Proses pemilihan data sesuai dengan analisa dan diambil dari berbagai sumber.

2. *Data Preprocessing*

   Proses pembersihan data (*Data Cleansing)*

3. *Data Transformation*

   Mengubah data agar sesuai dengan prosedur *data mining*

4. *Data Mining*

   Menerapkan langkah-langkah untuk mendapatkan pola tertentu.

5. *Interpretation and Evaluation*

   Mengolah hasil dan mengevaluasinya.

Sedangkan menurut *Ogwueleka, Francisca Nonyelum , 2009.* Langkah-langkah yang harus diambil dalam metodologi *data mining* adalah sebagai berikut :

1. *Sample*
2. *Explore*
3. *Modify*

4. Model

5. Assess

1.2. K-Means

Langkah algoritma *K-Means* menurut *MacQueen, J.B.(1967)* dijelaskan sebagai berikut :

Algoritma *K-Means* bertujuan untuk menentukan titik pusat dari *cluster*. Untuk menentukan titik minimum dari jarak kedua titik *cluster*, maka dapat dilakukan beberapa langkah seperti : Inisialisasi nilai K, Kumpulkan setiap nilai dan tempatkan terhadap titik pusat terdekat. Kemudian perbaharui nilai titik pusat hingga mencapai yang terdekat. Hitung jarak dengan titik pusat yang baru. Jika sudah terpenuhi, maka dapat berhenti. Jika belum, maka ulangi penempatan ke titik pusat baru. Untuk langkah awal, ada beberapa titik awal yang akan di segmentasi. Seperti contoh pada gambar 1 Tahapan Awal Segmentasi dibawah ini :

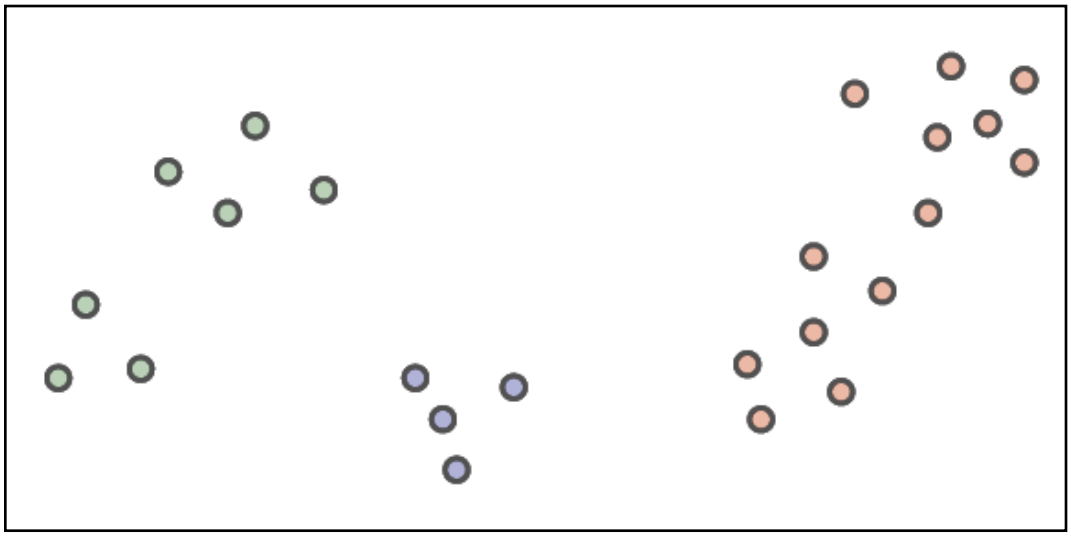

Gambar 1. Tahap Awal Segmentasi *(V, Sergei. V, Suresh. p: 7)*

Tahap selanjutnya adalah meminimalisir maksimum radius dari masing-masing radius segmentasi (radius masing-masing dihitung berdasarkan jarak yang paling dekat dengan metode *Euclidean distance*). Contoh *Clustering* dapat dilihat pada gambar 2. *Clustering*

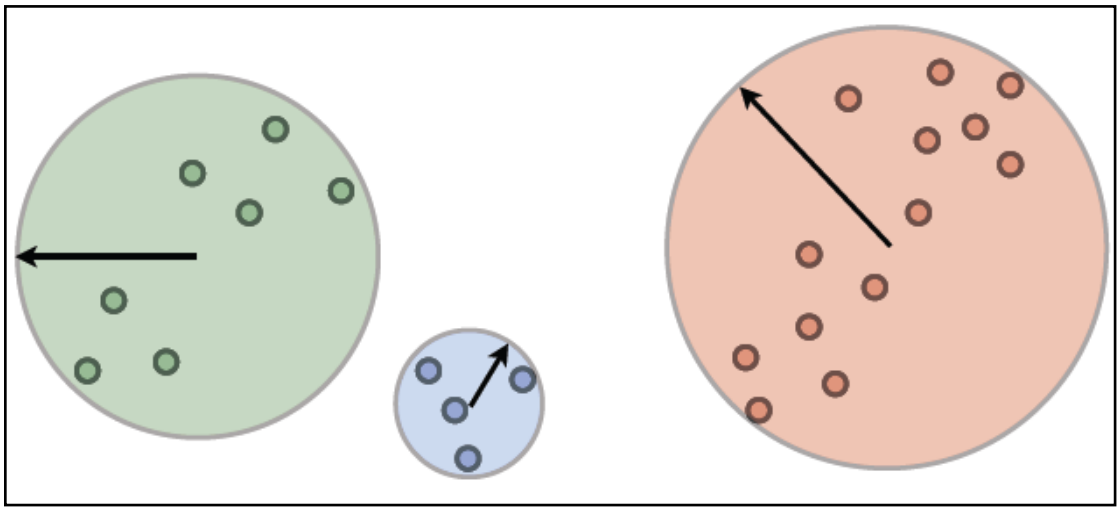

Gambar 2. *Clustering (V, Sergei. V, Suresh. p: 8)*

Algoritma *K-Means* atau langkah-langkah sederhana `dapat digambarkan seperti tahap-tahap dibawah ini :

1. Tahap Pertama, dibentuk sebuah *Data Set*, dapat dilihat pada gambar 3 *Data Set K-Means*

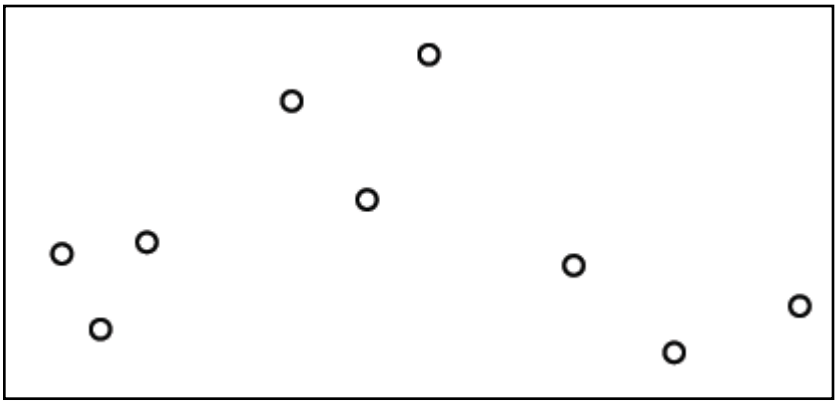

Gambar 3. Data Set K-Means *(V, Sergei. V, Suresh. p: 14)*

2. Tahap Kedua adalah memilih secara acak titik yang akan dijadikan sebagai titik pusat dari kluster, dapat dilihat pada gambar 4 Titik Pusat Segment

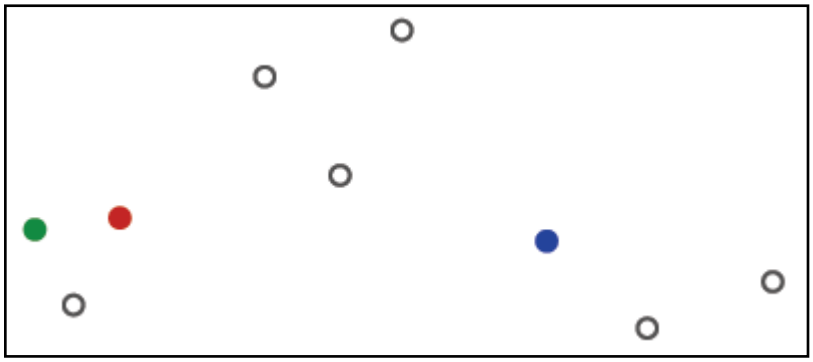

Gambar 4. Titik Pusat Segment*(V, Sergei. V, Suresh. p: 15)*

3. Tahap Ketiga adalah menentukan setiap titik ke titik pusat terdekat. Dapat dilihat pada gambar 5 Penentuan Titik Pusat

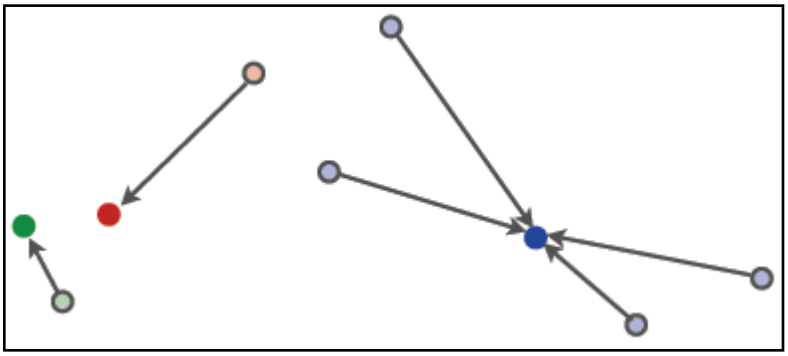

Gambar 5. Penentuan Titik Pusat *(V, Sergei. V, Suresh. p: 16)*

4. Tahap Keempat adalah tahap dimana perhitungan titik pusat akan berpindah sampai dimana penentuan titik pusat tidak berubah. Dapat dilihat pada gambar 6 Perpindahan Titik Pusat.

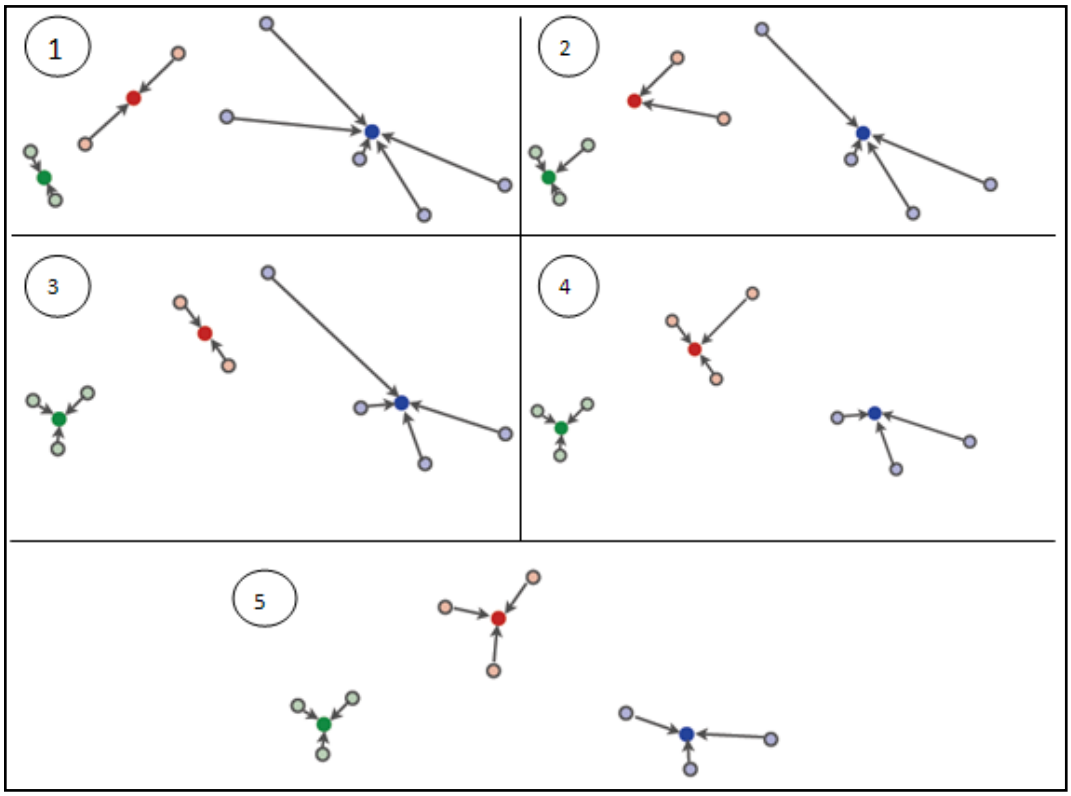

Gambar 6. Perpindahan Titik Pusat*(V, Sergei. V, Suresh. p:17)*

1.3. Euclidean Distance

Euclidean distance adalah salah satu cara untuk menghitung jarak antara titik poin dengan titik tengah kluster (*Centroid*). Nilai yang dihasilkan oleh perhitungan ini adalah nilai yang *Absolute*. Rumus untuk menghitung dengan *Euclidean distance* dapat ditunjukan pada gambar 7 Rumus *Euclidean distance*

$$D_{L_2}(x_2, x_1) = \|x_2 - x_1\|_2 = \sqrt{\sum_{j=1}^{p} \left(x_{2j} - x_{1j}\right)^2}$$

Gambar 7. Rumus *Euclidean distance*

1.4. Analisis RFM (*Recency, Frequency and Monetary*)

Menurut jurnal *A. Sumarwan, U. Sugema, I. Saefuddin, A. 2011*. Dikatakan bahwa tujuan dari analisis RFM sendiri adalah untuk memprediksi perilaku konsumen dimasa yang akan datang untuk memenuhi keputusan segmentasi nasabah ke arah yang lebih baik. Metode ini sendiri terdiri dari 2 cara *scoring* yaitu *Consumer Quintiles* dan *Behaviour Quintiles*. Namun metode yang akan dipakai adalah *Principal Component Analysis* untuk

menghitung bobot dari metrik R, F dan M. Langkah – langkah yang akan diambil dalam analisis ini adalah :

1. *Recency*.

   Recency adalah tahap pengambilan data pada database sesuai dengan cara mengurutkan data transaksi nasabah berdasarkan waktu transaksi dari waktu yang paling baru ke waktu yang paling lama.

2. *Frequency*

   Frequency adalah tahap pengambilan data nasabah sesuai dengan jumlah frekuensi transaksi yang dilakukan nasabah.

3. *Monetary*

   Monetary adalah tahap pengambilan data nasabah sesuai dengan nilai keuntungan yang diperoleh dari transaksi nasabah.

2. METODE PENELITIAN

Langkah pertama yang dilakukan adalah identifikasi dan analisis kebutuhan dari pengguna yang akan memanfaatkan hasil pengolahan data bersama-sama dengan mengamati keadaan *Data Warehouse* yang ada pada saat ini. Setelah itu dilanjutkan dengan tahap pengumpulan data-data sesuai informasi yang dibutuhkan untuk pengolahan data, kemudian diaplikasikan dengan algoritma yang tepat sehingga dicapai hasil sesuai dengan yang diharapkan dan berguna bagi pengguna. Berikut dijelaskan secara rinci tahapan pengerjaan yang akan dilakukan :

1. Identifikasi dan analisa kebutuhan data

   Tahap identifikasi dan analisa kebutuhan data dilakukan untuk mengetahui kebutuhan informasi yang pengguna butuhkan sehingga hasil dari penelitian sesuai dengan yang diharapkan oleh pengguna.

2. Studi literature

   Pada tahap Studi Literature peneliti mencari dan kemudian menganalisa jurnal-jurnal yang berhubungan dengan penelitian sehingga dapat menjadi pembanding ataupun menjadi sumber pustaka bagi penelitian ini.

3. Mengumpulkan dan menganalisa data

   Tahap ini merupakan tahap yang paling penting sekaligus dasar sebelum dilakukan pengolahan informasi yang ada pada *Data Warehouse*. Setelah dilakukan tahap pengamatan alur data, tahap ini dilakukan untuk mencari sumber data yang akan diolah walaupun data tersebut merupakan data kotor atau masih banyak data yang tidak valid.

Data yang masih kotor tersebut harus dianalisa terlebih dahulu agar pada saat proses pengolahan data, sumber data yang digunakan lebih efektif dan efisien seperti contohnya adalah penggunaan tipe variabel yang lebih sesuai dengan kebutuhan pengolahan data, selain itu juga dengan adanya analisa sumber data, peneliti dapat mengetahui mana data yang akan digunakan dan mana data yang tidak akan digunakan dan peneliti juga dapat mengetahui karakteristik data yang akan diolah. Sumber data yang digunakan adalah data transaksi nasabah, kemudian data nasabah, data rekening, data kode transaksi dan data produk.

4. Membersihkan dan mengolah data

   Setelah mengetahui sumber data yang akan digunakan untuk pengolahan *Data Mining,* diperlukan juga proses pembersihan data. Sumber data yang sudah dikumpulkan harus dibersihkan dengan cara membuang baris data yang bernilai tidak valid atau kosong, atau memperbaiki baris data yang kosong dengan data yang valid. Data yang sudah dibersihkan harus dicek kebenarannya atau divalidasi dengan menggunakan *query* untuk validasi data seperti pengecekan apakah masih ada baris yang kosong atau bernilai *null,* kemudian apakah semua data sudah berhubungan antara tabel satu dengan tabel yang lainnya. Untuk setiap baris data yang tidak valid dan juga tidak berhubungan antara tabel satu dengan yang lainnya akan dibuang dari calon *Data Set*. Biasanya proses ini dinamakan proses *Transformasi* data atau juga pengolahan data.

5. Mengolah menggunakan algoritma *K-Means*

   Setelah semua data diolah dan dibersihkan, tahap selanjutnya adalah pembentukan *Data Set* untuk diolah dengan menggunakan algoritma *K-Means* sehingga nantinya akan terbentuk beberapa kali iterasi berdasarkan nilai *k* pada masukan algoritma.

6. Evaluasi

   Tahap terakhir adalah dilakukan evaluasi terhadap hasil pengolahan *Data Mining* agar informasi dari pengolahan dapat berguna bagi pihak Manajemen dan dapat meningkatkan keuntungan perusahaan kedepannya.

Dari uraian diatas, langkah-langkah yang digunakan dalam penelitian ini dapat dilihat pada gambar 8 Metodologi Penelitian:

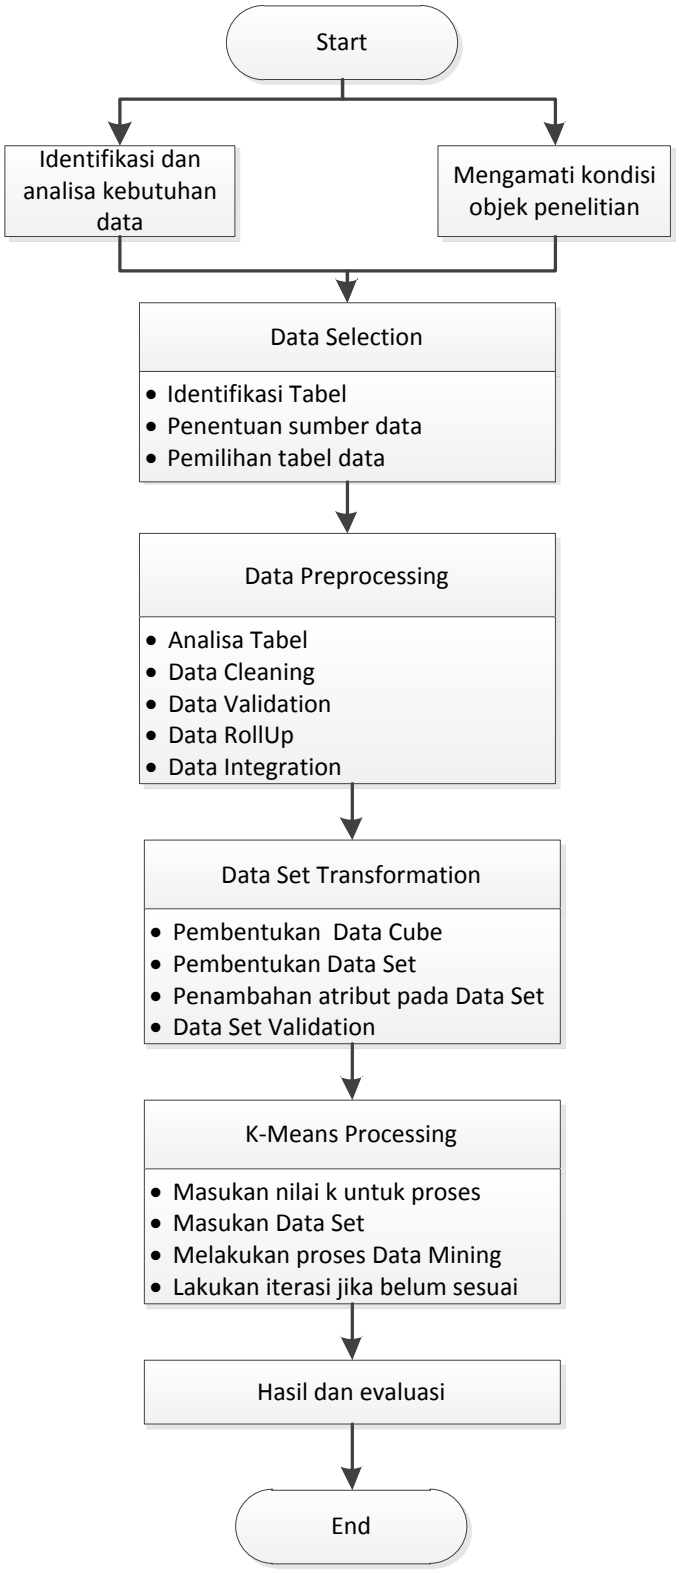

Gambar 8. Metodologi Penelitian

3. HASIL DAN PEMBAHASAN

3.1 Monetary vs Frequency

Proses *clustering* menggunakan metode K-Means dengan parameter RFM menggunakan k atau *clustering* sebanyak 8 bagian dan menggunakan *repository Monetary vs Frequency*. Setelah proses pengolahan data selesai, hasil *clustering* dapat dilihat pada gambar 9 Segmentasi *Monetary vs Frequency*

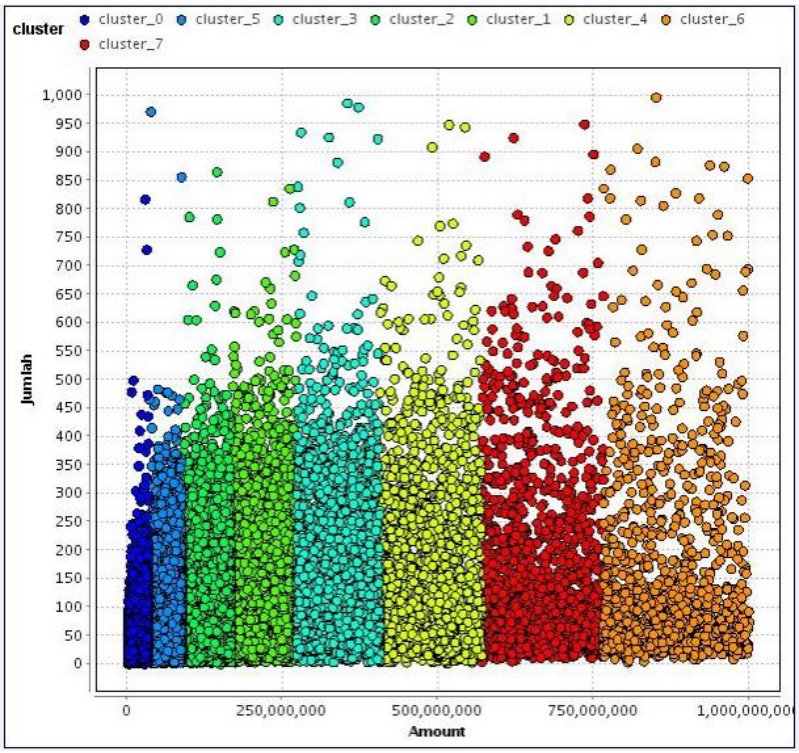

Gambar 9. Segmentasi *Monetary vs Frequency*

Hasil yang didapat setelah proses berdasarkan titik tengah atau *centroid* masing-masing *cluster* yang dapat dilihat pada Tabel 1 *Centroid Monetary vs Frequency*

Tabel 1. *Centroid Monetary vs Frequency*

Attribut	cluster_0	cluster_1	cluster_2	cluster_3	cluster_4	cluster_5	cluster_6	cluster_7
Jumlah	44	101	86	115	118	75	135	129
Amount	13,873,564	213,379,796	120,413,436	330,748,133	481,131,594	55,151,018	871,264,737	658,825,098

Berikut profil masing-masing *cluster* berdasarkan *Monetary vs Frequency* :

1. *Cluster 3, 4, 6* dan *7* merupakan *cluster* untuk nasabah yang mempunyai jumlah transaksi yang cukup banyak dan juga melakukan transaksi dalam jumlah uang yang besar. Biasanya nasabah yang seperti ini merupakan nasabah kelas menengah keatas

dengan jumlah 10469 baris data saja (8.48 %). *Cluster* ini dibagi lagi kedalam 4 bagian untuk dilakukan *scoring* sebagai berikut :

- *Cluster 6* akan diberi nilai 8.
- *Cluster 7* akan diberi nilai 7.
- *Cluster 4* akan diberi nilai 6.
- *Cluster 3* akan diberi nilai 5.

2. *Cluster 0, 1, 2* dan *5* merupakan *cluster* nasabah yang mempunyai transaksi dalam jumlah uang cukup rendah dan jumlah transaksi yang menengah. Pada *cluster* ini belum tentu merupakan nasabah yang mempunyai profil buruk, karena mungkin saja dengan jumlah transaksi yang cukup banyak namun jumlah uang yang ditransaksikan sedikit. Nasabah pada *cluster* ini sebanyak 113050 baris data (91.52 %). *Cluster* yang kedua juga dibagi lagi kedalam 4 bagian untuk dilakukan *scoring* sebagai berikut :
   - *Cluster 1* akan diberi nilai 4.
   - *Cluster 2* akan diberi nilai 3.
   - *Cluster 5* akan diberi nilai 2.
   - *Cluster 0* akan diberi nilai 1.

3.2 Recency vs Frequency

Proses *clustering* yang kedua dilakukan dengan menggunakan *repository* atau data menggunakan parameter *Recency vs Frequency* dan menggunakan k sebanyak 8 atau membagi kedalam 8 *cluster*. Setelah proses pengolahan data selesai, hasil *clustering* dapat dilihat pada gambar 10 Segmentasi *Recency vs Frequency.*

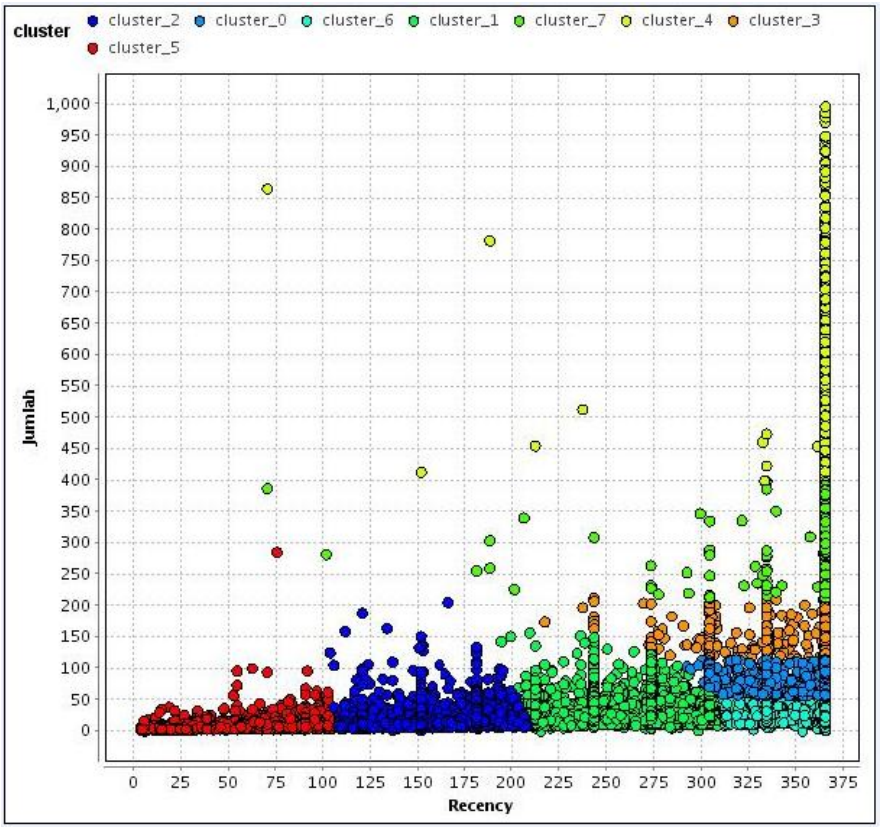

Gambar 10. Segmentasi *Recency vs Frequency*

Hasil yang didapat setelah proses berdasarkan titik tengah atau *centroid* masing-masing *cluster* yang dapat dilihat pada Tabel 2 *Centroid Recency vs Frequency*

Tabel 2. *Centroid Recency vs Frequency*

Attribut	cluster_0	cluster_1	cluster_2	cluster_3	cluster_4	cluster_5	cluster_6	cluster_7
Jumlah	79.5094	30.78002	18.16906	152.1501	514.5068	8.787185	36.05535	275.234
Recency	364.0033	258.238	154.5479	364.038	363.4743	59.52131	363.6888	364.0798

Berikut profil masing-masing *cluster* berdasarkan *Recency vs Frequency :*

1. *Cluster* 4, 7, 3 dan 0 merupakan *cluster* untuk nasabah yang memiliki jumlah transaksi yang banyak dan juga menunjukan nasabah tersebut aktif melakukan transaksi dengan data *recency* terakhir kapan nasabah tersebut bertransaksi. Pada *cluster* ini dapat dikatakan sebagai nasabah yang loyal walaupun tidak melihat jumlah transaksi nasabah tersebut karena nasabah pada *cluster* ini merupakan nasabah penyumbang *fee* terbanyak kepada bank. Pada *cluster* ini terdapat 43848 baris data (35.5%). Segmentasi ini akan dilakukan pemberian *score* untuk masing-masing *cluster* sebagai berikut :
   - *Cluster 4* akan diberi nilai 8.

- *Cluster 7* akan diberi nilai 7.
- *Cluster 3* akan diberi nilai 6.
- *Cluster 0* akan diberi nilai 5.

2. *Cluster* 5, 2, 1 dan 6 merupakan *cluster* untuk nasabah yang memiliki jumlah transaksi sedikit dan menunjukan bahwa nasabah tersebut tidak aktif melakukan transaksi. Nasabah ini biasa juga disebut nasabah *Dormant*. Biasanya diantara nasabah *dormant* ini terdapat cukup banyak nasabah berpotensial (mempunyai jumlah tabungan yang cukup tinggi) sehingga perlu dilakukan *follow up*. *Cluster* ini mempunyai 79671 baris data (64.5%), juga dibagi lagi kedalam 4 bagian untuk dilakukan *scoring* seperti berikut :
   - *Cluster 1* akan diberi nilai 4.
   - *Cluster 2* akan diberi nilai 3.
   - *Cluster 5* akan diberi nilai 2.
   - *Cluster 0* akan diberi nilai 1.

3.3 Recency vs Monetary

Proses *clustering* yang ketiga dilakukan dengan menggunakan *repository* atau data menggunakan parameter *Recency vs Monetary* dan menggunakan k sebanyak 8 atau membagi kedalam 8 bagian atau *cluster*.

Hasil yang didapat setelah proses berdasarkan titik tengah atau *centroid* masing-masing *cluster* yang dapat dilihat pada Tabel 3 *Centroid Recency vs Monetary*

Tabel 3. *Centroid Recency vs Monetary*

Attribut	cluster_0	cluster_1	cluster_2	cluster_3	cluster_4	cluster_5	cluster_6	cluster_7
Amount	870648045.41	328681846.44	54703645.61	13803469.98	119220069.96	479596213.15	211348565.31	658054705.50
Recency	355.32	353.49	350.62	325.80	340.35	351.76	351.44	354.76

Setelah proses pengolahan data selesai, hasil *clustering* dapat dilihat pada gambar 11 Segmentasi *Recency vs Monetary*.

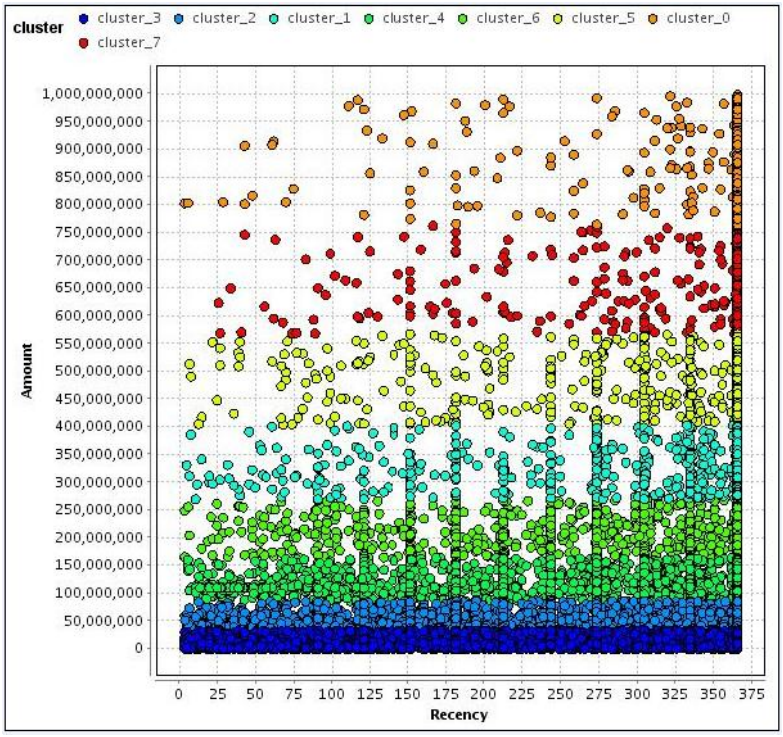

Gambar 11. Segmentasi *Recency vs Monetary*

Berikut profil masing-masing *cluster* berdasarkan *Recency vs Monetary :*

1. *Cluster* 0, 1, 5 dan 7 merupakan *cluster* untuk nasabah yang aktif dan mempunyai bertransaksi dalam jumlah yang relatif besar. Pada *cluster* ini terdapat 10553 baris data (8.54%). *Cluster* ini juga dibagi kedalam 4 bagian untuk dilakukan *scoring* sebagai berikut :
   - *Cluster 0* akan diberi nilai 8.
   - *Cluster 7* akan diberi nilai 7.
   - *Cluster 5* akan diberi nilai 6.
   - *Cluster 1* akan diberi nilai 5.
2. *Cluster* 2, 3 , 4 dan 6 merupakan *cluster* untuk nasabah yang kebanyakan kurang aktif dan mempunyai jumlah *monetary* yang rendah. Pada *cluster* ini terdapat 112966 baris data (91.46%). *Cluster* ini juga dibagi lagi kedalam 4 bagian untuk dilakukan *scoring* sebagai berikut :
   - *Cluster 6* akan diberi nilai 4.
   - *Cluster 4* akan diberi nilai 3.
   - *Cluster 2* akan diberi nilai 2.
   - *Cluster 3* akan diberi nilai 1.

4. KESIMPULAN

Dari penelitian yang sudah dilakukan, maka dapat ditarik kesimpulan bahwa hasil *Cluster* yang terbentuk dari hasil pengolahan *data mining* menggunakan pemodelan *k-means* dapat menunjukan kualitas nasabah secara garis besar berdasarkan segmentasi nasabah, Berikut kesimpulan yang didapat :

1. Hasil segmentasi ini berdasarkan *scoring* yang telah dilakukan masing-masing *cluster* dan berdasarkan *Recency, Monetary* dan *Frequency* sehingga semakin tinggi *score* yang didapat, maka akan semakin bagus hasil penilaian terhadap nasabah itu sendiri. Nasabah yang mempunyai *score* terbaik hanya berjumlah 0.09 % dari total nasabah, nasabah ini mempunyai kecenderungan jumlah *Frequency* yang tinggi dan jumlah *Monetary* yang tinggi.
2. Jumlah *score* yang paling tinggi berada pada *score* 6 yaitu sebanyak 31.42 % dari total nasabah, menandakan nasabah yang aktif bertransaksi namun jumlah transaksinya tidak banyak, selain itu juga secara *monetary* masih rendah. Hal ini menandakan bahwa nasabah pada *score* 6 jarang bertransaksi , selain itu juga jika melakukan transaksi dalam jumlah kecil saja.
3. Diperlukan *follow up* ataupun promosi-promosi agar nasabah tertarik untuk melakukan transaksi sehingga mendatangkan *fee* yang lebih besar, selain itu juga harus dibuat *product* baru untuk menjangkau nasabah mengengah ke bawah dengan kemudahan transaksi dan memiliki *feature* produk yang lebih baik daripada bank kompetitor sehingga akan mendongkrak tingkat kepopuleran di mata nasabah (*brand image).*

DAFTAR PUSTAKA

Ali Farajian, Mohammad. Mohammadi, Shahriar. December 2010. Mining the Banking Customer Behavior using Clustering and Association Rules Method. International Journal of Industrial Engineering & Production Research. ISSN: 2008-4889.

Aviliani. Sumarwan, U. Sugema, I. Saefuddin, A. 1 Juni 2011. SEGMENTASI NASABAH TABUNGAN MIKRO BERDASARKAN RECENCY, FREQUENCY, DAN MONETARY : KASUS BANK BRI. ISSN 1410-8623.

Bhambri, Vivek. 2 June 2011. Application of Data Mining in Banking Sector. ISSN : 0976-8491.

Chakrabarti, et al. 2009. Data Mining Know It All, Morgan Kaufmann Publisher.

Dash, Rajanish. 2006. DATA MINING IN BANKING AND FINANCE. A NOTE FOR A BANKERS.

Kohavi, Ron. Parekh, Rajesh. 2004. Visualizing RFM Segmentation.

MacQueen, J.B. 1967. Some methods for classification and Analysis of Multivariate Observations. Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probablitiy. University of California Press.

Mason, C. 2003. Recency, Frequency and Monetary Analysis. Kenan-Flagler Business School, The University of North Carolina.

Miglautsch, John R. 2001. ISSM Electronic Journal. International Society for Strategic Marketing.

Niyagas, Waminee. Srivihok, Anongnart. Kitisin, Sukumal. Januari 2010. Clustering e-Banking Customer using Data Mining and Marketing Segmentation. Department of Computer Science, Faculty of Science, Kasetsart University, Bangkok.

Ogwueleka, Francisca Nonyelum. 2009. Potential Value of Data Mining for Customer Relationship Marketing in Banking Industry. ISSN 1995-0772.

S. Moertini, Veronica. 2002. INTEGRAL vol. 7 no. 1. Universitas Parahyangan, Bandung.

Tang, ZhaouHui. Maclennan, Jammie. Data Mining With SQL Server 2005. Wiley Publishing, Inc. Indianapolis, Indiana. 2005

V, Sergei. V, Suresh. Theory of Clustering. 2010.