

REKOMENDASI PRODUK BERDASARKAN LOYALITAS PELANGGAN MENGGUNAKAN INTEGRASI METODE AHP DAN TEKNIK PENGALIAN DATA: STUDI KASUS CV. XYZ

Dita Kurniawaty, Arif Djunaidy, Renny P. Kusumawardani

Jurusan Sistem Informasi, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember
Kampus ITS, Jalan Raya ITS Sukolilo, Surabaya 60111

E-mail: dita.kurniawaty@gmail.com, adjunaidy@is.its.ac.id, renny@is.its.ac.id

Abstrak

Salah satu faktor penting dalam mempertahankan pelanggan adalah dengan memberikan pelayanan yang sesuai dengan karakteristik pelanggan, misalnya dengan pemberian rekomendasi produk sesuai lifetime value. Rekomendasi yang tepat akan meningkatkan kemungkinan penjualan silang dan membangun loyalitas. Makalah ini menyajikan penerapan Analytic Hierarchy Process (AHP) dan klasterisasi untuk melakukan segmentasi pelanggan dengan studi kasus suatu perusahaan konfeksi. Tingkat loyalitas pelanggan dianalisis dengan RFM (Recency, Frequency, Monetary) dan dikombinasikan dengan AHP untuk menentukan bobot relatif RFM. Hasil analisis kemudian diklasterisasi dengan algoritma fuzzy c-means. Untuk menguji efektivitas langkah-langkah tersebut, dilakukan rekomendasi produk dengan association analysis dengan FP-Growth dan collaborative filtering dengan algoritma k-nearest neighbor. Hasil eksperimen menunjukkan bahwa segmentasi dengan RFM memberikan peningkatan secara signifikan pada rekomendasi produk dengan association analysis, yaitu sebesar 13% terhadap F1-Measure. Integrasi dengan pembobotan AHP meningkatkan lebih jauh kualitas rekomendasi sebesar 6%. Kombinasi kedua metode ini tidak terlalu berpengaruh pada teknik collaborative filtering dengan k-Nearest Neighbor, yaitu memberikan peningkatan sebesar 0.17%.

Kata kunci: analisis RFM (Recency, Frequency, dan Monetary), metode AHP (Analytic Hierarchy Process), teknik penggalian data, perilaku dan loyalitas pelanggan, customer relationship management.

Abstract

One of the most important strategy in customer retention is by delivering services that match the characteristic of the customer. An implementation of this strategy is by giving product recommendations which suits the customer's lifetime value. Good recommendations could increase the potential for cross-selling and customer loyalty. This paper presents the application of Analytic Hierarchy Process (AHP) and clustering to perform customer segmentation with the study case on a clothing company. Customer loyalty is analyzed with respect to their RFM (Recency, Frequency, Monetary) combined with the AHP for determining the weights of each of the RFM variables. The result is the clustered using Fuzzy C-Means. The effectiveness of the segmentation steps is then tested by performing product recommendation using association analysis with FP-Growth and collaborative filtering with k-Nearest Neighbor algorithm. Experiments demonstrate that RFM-based segmentation increases the quality of product recommendation with association analysis by 13% on F1-Measure. Combining this with AHP-weighting increases the performance further by 6%. However, the combination of these segmentation techniques only increases the performance of collaborative filtering with k-Nearest Neighbor by 0.17%.

Kata kunci: analisis RFM (Recency, Frequency, dan Monetary), AHP (Analytic Hierarchy Process), data mining technique, customers behavior and loyalty, customer relationship management.

1. PENDAHULUAN

Industri konveksi dalam beberapa tahun terakhir menjadi ladang bisnis yang cukup menjanjikan karena sandang sebagai kebutuhan primer manusia yang tidak dapat digantikan. Bisnis ini memiliki pangsa pasar yang sangat luas, tren dan mode yang dinamis dalam mengikuti perkembangan zaman. Fokus perusahaan modern telah beralih dari strategi *product/service-oriented* menjadi *customer-oriented* [3]. Para produsen perlu menerapkan strategi untuk meningkatkan mutu produk dan melakukan inovasi layanan terbaik dalam menghasilkan produk yang kreatif untuk memenangkan persaingan dengan kompetitor. Salah satu cara yang dapat digunakan untuk mengelola hubungan dengan pelanggan adalah mengidentifikasi karakteristik pelanggan dengan membagi pelanggan berdasarkan kesamaan perilaku dan menyediakan rekomendasi produk yang tepat bagi mereka.

Pencarian informasi ini dilakukan dengan cara penggalian data (*data mining*) dan analisis kluster untuk segmentasi pelanggan (*clustering analysis*). Perilaku pembelian di masa lalu dapat menunjukkan seberapa besar loyalitas pelanggan [5]. Pelanggan dikatakan loyal apabila melakukan lebih banyak pembelian dan menghabiskan lebih banyak uang selama siklus hidup pembelian. Sebaliknya, pelanggan yang tidak loyal adalah pelanggan dengan jumlah pembelian lebih rendah dan menghabiskan lebih sedikit uang. Model *RFM* (*recency, frequency, monetary*) adalah salah satu model untuk mengevaluasi loyalitas pelanggan dengan mempertimbangkan semua data historikal pembelian di masa lalu untuk memprediksi perilaku pelanggan di masa depan [2]. Metode *AHP* digunakan untuk memberi bobot pada setiap kriteria model *RFM* guna mengetahui tingkat kepentingan relatif dari tiga kriteria tersebut. Proses klusterisasi dilakukan untuk membagi pelanggan yang memiliki kesamaan karakter ke dalam segmen-segmen didasarkan pada analisis model *RFM* terbobot. *Fuzzy c-means* adalah salah satu metode klusterisasi dimana keberadaan titik-titik data dalam suatu kluster ditentukan oleh derajat keanggotaannya. Tahap terakhir merumuskan aturan rekomendasi produk dan melakukan uji coba untuk mengetahui perbandingan performansi metode yang digunakan dan mengetahui pengaruh dari loyalitas pelanggan dan pembobotan *AHP* dalam meningkatkan kualitas rekomendasi produk. Metode yang digunakan adalah penggalian aturan asosiasi yang memanfaatkan algoritma *FP-Growth* dan *collaborative filtering* yang memanfaatkan algoritma *k-nearest neighbor* (*k-NN*).

2. METODE

2.1 Analisis Loyalitas Pelanggan berbasis Model RFM

Customer Lifetime Value (CLV) digunakan untuk menilai loyalitas pelanggan yang berkontribusi memberikan *value* bagi perusahaan. Model yang populer digunakan untuk menilai loyalitas pelanggan adalah *RFM* dikenalkan oleh Hughes (1994), dibangun berdasarkan tiga kriteria :

- Recency* : mengacu pada durasi waktu/periode pembelian terakhir dengan saat ini; nilai yang lebih rendah sesuai dengan probabilitas yang lebih tinggi dari pelanggan yang melakukan pembelian secara berulang,
- Frequency* : banyaknya jumlah pembelian yang dilakukan dalam jangka waktu/periode tertentu; frekuensi yang lebih tinggi menunjukkan loyalitas yang lebih besar,
- Monetary* : nilai total pembelian yang dihabiskan selama periode tertentu; jumlah yang lebih tinggi menunjukkan kontribusi yang besar bagi perusahaan.

Periode analisis ditentukan 1 Agustus 2010 hingga 1 Agustus 2011 sebanyak 485 transaksi dari 169 pelanggan.

2.2 Penggunaan Analytical Hierarchy Process (AHP) untuk Pembobotan Model RFM

Metode *AHP* digunakan untuk menentukan bobot prioritas kriteria model *RFM* dinotasikan dengan w_R , w_F , dan w_M . Metode *AHP* diimplementasikan pada hasil kuisioner yang telah diberikan kepada pihak yang berkompeten dalam menilai pengaruh kriteria *recency*, *frequency*, dan *monetary* terhadap operasional perusahaan. Bobot tersebut dikalikan dengan nilai kriteria model *RFM* sebagai penentu peringkat kluster dengan Persamaan (1).

$$RFM \text{ terbobot} = w_R \times R + w_F \times F + w_M \times M \quad (1)$$

Semakin tinggi peringkatnya, maka semakin besar tingkat kelayakan pelanggan dalam kluster tersebut.

2.3 Algoritma Fuzzy C-Means

Metode kluster *Fuzzy C-Means* ditemukan pertama kali oleh Dunn pada tahun 1973 dan kemudian dikembangkan oleh Jim Bezdek pada tahun 1981 [4]. *Fuzzy C-Means* merupakan salah satu metode pengelompokan data dimana keberadaan titik-titik data dalam suatu kluster ditentukan oleh derajat keanggotaannya. Metode ini memungkinkan satu data menjadi bagian dalam satu atau lebih kluster. Data keluaran hasil perhitungan nilai *RFM* harus melewati proses normalisasi sebelum dikalikan dengan bobot prioritas, untuk menyamakan dampak atau pengaruh dari ketiga kriteria pada nilai data model *RFM* terhadap tingkat loyalitas pelanggan. Normalisasi untuk kriteria *recency* menggunakan persamaan $x' = (x^L - x) / (x^L - x^S)$ karena nilai *recency* berdampak negatif terhadap tingkat loyalitas pelanggan. Sedangkan untuk normalisasi kriteria *frequency* dan *monetary* menggunakan persamaan $x' = (x - x^S) / (x^L - x^S)$ karena *frequency* dan *monetary* memberikandampak positif terhadap loyalitas pelanggan.

2.4 Kaidah Penggalian Aturan Asosiasi

Langkah awal dalam melakukan rekomendasi produk adalah menghimpun seluruh informasi mengenai histori pembelian produk oleh pelanggan, meliputi semua pola kombinasi produk yang telah dibeli oleh setiap pelanggan. Salah satu teknik penggalian data yang handal untuk mengetahui pola tersebut adalah analisis asosiasi (*association rule mining*) untuk menemukan aturan asosiatif antara suatu kombinasi item. Semua data transaksi pelanggan pada pembelian masa lalu dikelompokkan ke dalam kluster. Metode penggalian aturan asosiasi kemudian digunakan untuk melakukan ekstraksi aturan rekomendasi dari transaksi yang terkait pada setiap kluster, bukan dengan seluruh transaksi pelanggan.

2.5 Algoritma FP-Growth

Algoritma *Frequent Pattern Growth (FP-Growth)* adalah pengembangan algoritma *Apriori* dari teknik penggalian aturan asosiasi yang sering digunakan dalam menemukan aturan asosiatif suatu kombinasi item. *FP-Growth* menggunakan pendekatan yang berbeda dari paradigma yang digunakan oleh algoritma *apriori*. Pada algoritma *apriori*, diperlukan himpunan kandidat untuk mendapatkan data yang paling sering muncul. Sedangkan pada algoritma *FP-Growth*, menggunakan konsep perluasan pohon prefix yang biasa disebut *FP-tree (frequent pattern tree)* dalam pencarian himpunan data yang paling sering muncul. *FP-Growth* dapat langsung mengekstrak himpunan data yang paling sering muncul dari *FP-tree* yang terbentuk menggunakan prinsip *divide and conquer*.

2.6 Konsep Collaborative Filtering

Teknik ini menggunakan preferensi pembelian produk untuk menghitung kesamaan antar pelanggan dengan memanfaatkan algoritma *k-nearest neighbor (k-NN)* untuk menghitung kedekatan jarak antar pelanggan. Dalam *collaborative filtering* pelanggan akan diurutkan berdasarkan kesamaan mereka dalam kaitannya dengan pelanggan *u*. Nilai *k* yang paling mirip (ranking tertinggi) dengan pelanggan dipilih sebagai *k-nearest neighbors* untuk pelanggan *u*.

2.7 Algoritma K-Nearest Neighbor (kNN)

Bentuk paling umum dari teknik *collaborative filtering* adalah pendekatan berbasis ketetanggaan atau yang lebih dikenal sebagai *k-nearest neighbor (k-NN)*. Algoritma ini digunakan untuk melakukan klasifikasi terhadap objek berdasarkan data pembelajaran yang jaraknya paling dekat dengan objek tersebut [1]. Dekat atau jauhnya tetangga dihitung menggunakan rumus *Euclidean*.

3. PENGOLAHAN DATA

Sebagaimana disebutkan dalam bagian Metode, analisis dilakukan pada 485 data transaksi dari 169 pelanggan yang melakukan transaksi dari tanggal 1 Agustus 2010 hingga 1 Agustus 2011. Hasil dari pengolahan data tersebut sesuai metode dijabarkan berikut ini.

3.1 Penilaian Pelanggan Berbasis Model RFM

Data nilai *recency* mengacu pada durasi waktu pembelian terakhir dengan periode analisis. Semakin rendah nilai *R* semakin dekat pula jarak waktu pembelian terakhir dengan periode analisis sehingga mengindikasikan probabilitas yang lebih tinggi dari pelanggan untuk melakukan pembelian produk secara berulang. Data nilai *frequency* menunjukkan banyaknya transaksi yang dilakukan selama periode analisis. Semakin tinggi nilai *F*, semakin banyak pula jumlah transaksi yang dilakukan pelanggan dan mengindikasikan loyalitas yang lebih besar. Data nilai *monetary* merujuk pada total pembelian yang dihabiskan oleh setiap pelanggan selama periode tertentu. Jumlah pembelian yang lebih tinggi menunjukkan kontribusi pelanggan yang besar bagi perusahaan. Tabel 1 menunjukkan hasil penilaian pelanggan berbasis model RFM.

3.2 Pembobotan AHP untuk Penentuan Bobot Prioritas Kriteria Model RFM

Metode AHP diimplementasikan pada hasil kuisioner yang telah dilakukan. Dari hasil perhitungan tersebut, kriteria *Frequency* memiliki bobot yang lebih tinggi daripada kedua bobot lainnya. Dengan demikian dapat diambil kesimpulan bahwa kriteria *Frequency* memiliki pengaruh yang lebih besar bagi perusahaan daripada kriteria *Recency* dan *Monetary*. Hasil perhitungan tersebut disajikan pada Tabel 2.

Tabel 24 Hasil Penilaian Pelanggan Berbasis Model RFM

Kriteria	Minimum	Maksimum	Rata-Rata
Recency	3	356	97,047
Frequency	1	114	3,183
Monetary	144.500	345.950.000	20.291.653,85

Tabel 3 Hasil Perhitungan Bobot AHP setiap Kriteria RFM

Kriteria	Bobot Prioritas
Recency	0,12
Monetary	0,32
Frequency	0,56

3.3 Klasterisasi dengan Metode Fuzzy C-Means

Tahap klasterisasi menggunakan algoritma *fuzzy c-means* diaplikasikan dengan bantuan perangkat lunak *R-Program*. Data yang digunakan sebagai masukan adalah data nilai *RFM* normalisasi tanpa bobot dan data nilai *RFM* normalisasi dengan bobot. Hasil dari klasterisasi ini ditunjukkan pada Tabel 3.

3.4 Perumusan Aturan Rekomendasi Produk

a) Perumusan Aturan Rekomendasi Produk dengan Teknik Penggalian Aturan Asosiasi yang memanfaatkan Algoritma FP-Growth

Data-data yang akan diproses untuk menentukan aturan rekomendasi produk menggunakan algoritma *FP-Growth* adalah data preferensi pembelian produk yang dilakukan pelanggan selama periode analisis yang telah dihasilkan dalam proses klasterisasi tahap sebelumnya, yaitu:

- Data preferensi pembelian seluruh pelanggan tanpa pengelompokan/klaster, menghasilkan 258 aturan.

- ii. Data preferensi pembelian pelanggan dalam data klaster berbasis RFM tanpa bobot.
 iii. Data preferensi pembelian pelanggan dalam data klaster berbasis RFM dengan bobot.
 Jumlah aturan yang dihasilkan pada kondisi ii dan iii untuk masing-masing klaster disajikan pada Tabel 4(a)(b).

Tabel 25 (a) Hasil Klasterisasi Data Nilai RFM

Normalisasi Tanpa Bobot							Normalisasi Dengan Bobot						
Klaster	Jumlah Anggota	Recency	Frequency	Monetary	Time	Peringkat	Klaster	Jumlah Anggota	Recency	Frequency	Monetary	Time	Peringkat
1	4	0,89132	0,41573	0,80489	R↓F↑M↑	1	6	20	0,012826	0,003706	0,002543	0,019074	8
2	21	0,10004	0,01417	0,01417	R↓F↓M↓	8	2	4	0,095237	0,219870	0,234325	0,549432	1
3	17	0,61774	0,03395	0,03003	R↓F↓M↓	6	3	21	0,052465	0,021731	0,011722	0,085917	7
4	57	0,95138	0,02059	0,02024	R↑F↑M↓	4	4	34	0,108321	0,040036	0,017504	0,165861	4
5	17	0,40094	0,02849	0,03075	R↓F↓M↓	7	5	49	0,112801	0,005652	0,005000	0,123452	5
6	20	0,96554	0,12873	0,08213	R↑F↓M↓	3	6	5	0,113557	0,248173	0,043217	0,404948	2
7	6	0,96620	0,37785	0,13622	R↑F↑M↑	2	7	18	0,081565	0,006909	0,005535	0,094009	6
8	27	0,80959	0,05073	0,04200	R↑F↓M↓	5	8	18	0,112580	0,096031	0,037103	0,245714	3
Rata-Rata		0,73479	0,06158	0,05502			Rata-Rata		0,086169	0,080264	0,044619		

Tabel 4 (b) Rekomendasi Produk Data Berbasis Model RFM

Jumlah Aturan yang Dihasilkan		No. Klaster							
		1	2	3	4	5	6	7	8
Model RFM	Tanpa Bobot	294	76	767	221	668	205	792	622
	Dengan Bobot	62	294	346	247	273	18	792	299

b) Perumusan Aturan Rekomendasi Produk dengan Teknik Collaborative Filtering yang memanfaatkan Algoritma k-Nearest Neighbor (kNN)

Perumusan rekomendasi produk dilakukan pada data preferensi pembelian produk pelanggan yang telah dihitung jarak kedekatannya dengan algoritma *k-NN* berdasarkan dua kondisi berikut :

- a) Jarak kedekatan pelanggan berdasarkan preferensi produk yang dibeli dengan $k = 10, 25, 50, 75, 90, 100, 110$.
 b) Jarak kedekatan pelanggan berdasarkan nilai RFM normalisasi berbobot dengan nilai $k = 10, 25, 50, 75, 90, 100, 110$.

Jumlah aturan yang dihasilkan pada kedua kondisi ini disajikan pada Tabel 5.

Tabel 5 Rekomendasi Produk kepada Pelanggan berdasarkan Kedekatan Jarak Preferensi Pembelian Produk

Jumlah Aturan		Jumlah Tetangga Terdekat (Nearest Neighbor)						
		10	25	50	75	90	100	110
Kondisi	Berdasarkan produk yang dibeli	301	439	383	367	396	365	348
	Berdasarkan nilai RFM ternormalisasi terbobot	188	205	200	258	284	284	275

4. UJI COBA DAN ANALISIS HASIL

4.1 Data Uji Coba

Data untuk uji coba adalah data preferensi pembelian pelanggan untuk mengetahui pengaruh loyalitas pelanggan berbasis model *RFM* dan pembobotan *AHP* dalam meningkatkan kualitas rekomendasi produk, yaitu :

- Data preferensi pembelian pelanggan non-klaster
- Data preferensi pembelian pelanggan dalam data klaster berbasis RFM tidak terbobot
- Data preferensi pembelian pelanggan dalam data klaster berbasis RFM terbobot
- Data preferensi pembelian pelanggan berdasarkan kedekatan jarak preferensi pembelian produk
- Data preferensi pembelian pelanggan berdasarkan kedekatan jarak nilai RFM

4.2 Skenario dan Hasil Uji Coba

Skenario yang digunakan dalam melakukan uji coba untuk mengukur kualitas rekomendasi produk adalah :

a) Skenario perbandingan kualitas rekomendasi produk pada data klaster berbasis model RFM berbobot dengan data non-klaster.

Skenario ini untuk membuktikan penggunaan model *RFM* dan segmentasi yang dilakukan memberikan pengaruh dalam meningkatkan kualitas rekomendasi produk kepada pelanggan dengan membandingkan kualitas rekomendasi produk yang dihasilkan menggunakan teknik penggalian aturan asosiasi yang memanfaatkan algoritma *FP-Growth* pada seluruh data preferensi pembelian yang dilakukan pelanggan selama periode analisis dengan kualitas rekomendasi produk yang dihasilkan pada data preferensi pembelian yang dilakukan pelanggan di setiap segmen hasil klasterisasi data berbasis model *RFM* terbobot mengacu pada metrik *F1-Measure*. Tabel 9 adalah hasil perbandingan kualitas rekomendasi produk.

b) Skenario perbandingan kualitas rekomendasi produk pada data klaster berbasis RFM terbobot dengan data klaster berbasis RFM tidak terbobot.

Skenario ini untuk membuktikan metode pembobotan *AHP* memberikan pengaruh meningkatkan kualitas rekomendasi produk dengan membandingkan kualitas rekomendasi produk yang dihasilkan menggunakan teknik penggalan aturan asosiasi yang memanfaatkan algoritma *FP-Growth* pada data preferensi pembelian yang dilakukan pelanggan selama periode analisis di setiap segmen hasil klasterisasi data berbasis model *RFM* terbobot dengan kualitas rekomendasi produk yang dihasilkan setiap segmen hasil klasterisasi data berbasis model *RFM* tidak terbobot mengacu pada metrik *F1-Measure*. Tabel 6 menunjukkan hasil perbandingan kualitas rekomendasi produk.

Tabel 6 Nilai *Recall*, *Precision* dan *F1-Measure* pada Data Klaster Berbasis Model *RFM*

Peringkat Klaster	Kondisi Klaster Normalisasi dengan Bobot			Kondisi Klaster Normalisasi tanpa Bobot			Kondisi Non-Klaster		
	Recall	Precision	F1	Recall	Precision	F1	Recall	Precision	F1
1	0.5983	0.3047	0.3804	0.5808	0.2979	0.3727	0.5623	0.2724	0.3459
2	0.2687	0.3399	0.2831	0.3973	0.2040	0.2511	0.3749	0.2302	0.2688
3	0.4831	0.2801	0.3312	0.4368	0.2378	0.2901	0.4056	0.2449	0.2883
4	0.4077	0.2667	0.3025	0.4493	0.2414	0.2898	0.4239	0.2511	0.2737
5	0.4679	0.2652	0.3001	0.4993	0.2251	0.2880	0.3899	0.2226	0.2613
6	0.3821	0.2559	0.2927	0.4425	0.2510	0.2731	0.4514	0.2113	0.2549
7	0.3525	0.2620	0.2885	0.4163	0.2097	0.2705	0.3105	0.2239	0.2535
8	0.2224	0.2094	0.1998	0.3156	0.1527	0.1888	0.5217	0.1263	0.1838
Rata-Rata	0.402	0.262	0.291	0.436	0.225	0.274	0.414	0.220	0.258

c) Skenario perbandingan kualitas rekomendasi produk pada kelompok pelanggan berdasarkan kedekatan preferensi pembelian produk dengan kelompok pelanggan berdasarkan kedekatan nilai RFM.

Skenario ini untuk membuktikan sekali lagi apakah penggunaan loyalitas pelanggan berbasis model *RFM* dan pembobotan *AHP* benar-benar memberikan pengaruh dalam meningkatkan kualitas rekomendasi produk dengan membandingkan kualitas rekomendasi produk yang dihasilkan menggunakan penggalan aturan asosiasi yang memanfaatkan algoritma *FP-Growth* pada data preferensi pembelian yang dilakukan pelanggan sebanyak k berdasarkan kedekatan jarak preferensi pembelian produk oleh masing-masing pelanggan dengan kualitas rekomendasi produk yang dihasilkan pada data preferensi pembelian yang dilakukan pelanggan sebanyak k berdasarkan kedekatan jarak nilai *RFM* terbobot mengacu pada metrik *F1-Measure*. Tabel 7 menunjukkan hasil kualitas rekomendasi produk yang dihasilkan.


Tabel 7 Nilai Metrik *Recall*, *Precision* dan *F1-Measure* pada Data Kelompok Pelanggan

Berdasarkan Kedekatan Jarak Preferensi Pembelian				Pelanggan Berdasarkan Kedekatan Jarak Nilai RFM Terbobot			
k	Recall	Precision	F1-Measure	k	Recall	Precision	F1-Measure
10-NN	0.4831	0.3008	0.3485	10-NN	0.5580	0.2988	0.3640
25-NN	0.4931	0.3044	0.3572	25-NN	0.5664	0.3025	0.3678
50-NN	0.5036	0.3073	0.3643	50-NN	0.5646	0.3040	0.3707
75-NN	0.5160	0.3120	0.3693	75-NN	0.5864	0.3038	0.3727
90-NN	0.5202	0.3155	0.3705	90-NN	0.5666	0.3013	0.3686
100-NN	0.5118	0.3077	0.3655	100-NN	0.5721	0.2871	0.3533
110-NN	0.5030	0.3025	0.3598	110-NN	0.5608	0.2849	0.3484

4.3 Analisis

a) Analisis Perbandingan Loyalitas Pelanggan Berbasis Model RFM Terbobot dan Non-RFM


Hasil uji coba menunjukkan bahwa nilai metrik *F1-Measure* setiap klaster pada data klaster berbasis model *RFM* terbobot mengalami peningkatan sejalan dengan peringkat yang dimiliki, kecuali nilai metrik *F1-Measure* pada klaster peringkat 2. Nilai metrik *F1-Measure* setiap klaster pada data non-klaster pun mengalami peningkatan sesuai dengan peringkat klaster. Gambar 1 menunjukkan grafik perbandingan nilai metrik *F1-Measure* untuk masing-masing klaster pada kedua data. Grafik menunjukkan bahwa nilai metrik *F1-Measure* setiap klaster pada data klaster berbasis model *RFM* terbobot (garis biru) lebih besar daripada nilai metrik *F1-Measure* setiap klaster dengan peringkat yang sama pada data non-klaster (garis merah). Maka, dapat dikatakan bahwa aturan rekomendasi produk yang diekstrak dari data pembelian oleh pelanggan dalam setiap klaster berbasis model *RFM* terbobot memberikan kualitas yang lebih baik daripada tanpa adanya klaster berbasis model *RFM*.



Gambar 1 Grafik Perbandingan Nilai Metrik F1-Measure pada Data Klaster Berbasis RFM Terbobot dengan Data Non-Klaster

b) Analisis Perbandingan Loyalitas Pelanggan Berbasis Model RFM Terbobot dan Tidak Terbobot

Hasil uji coba menunjukkan bahwa nilai metrik *F1-Measure* setiap klaster pada data berbasis model *RFM* terbobot maupun tidak terbobot, keduanya mengalami peningkatan sejalan dengan peringkat yang dimiliki, kecuali nilai *F1-Measure* pada klaster peringkat 2 yang lebih rendah dibanding dengan klaster peringkat 3. Nilai *F1-Measure* untuk setiap klaster yang dihasilkan dari tahap uji coba kemudian dibandingkan berdasarkan masing-masing peringkat klaster. Gambar 2 menunjukkan grafik perbandingan nilai metrik *F1-Measure* untuk masing-masing klaster pada kedua data. Grafik menunjukkan bahwa nilai metrik *F1-Measure* untuk setiap klaster pada data klaster berbasis model *RFM* terbobot (ditunjukkan oleh garis berwarna biru) lebih besar daripada nilai metrik *F1-Measure* setiap klaster dengan peringkat yang sama pada data data klaster berbasis model *RFM* tidak terbobot (ditunjukkan oleh garis berwarna hijau). Maka, dapat dikatakan bahwa aturan rekomendasi produk yang diekstrak dari data preferensi pembelian produk oleh pelanggan dalam setiap klaster berbasis model *RFM* yang memiliki bobot pada setiap kriteria memberikan kualitas lebih baik daripada aturan dalam klaster berbasis *RFM* tidak terbobot.



Gambar 2 Grafik Perbandingan Nilai Metrik F1-Measure pada Data Klaster Berbasis RFM Terbobot dengan Tidak Terbobot


c) Analisis Perbandingan Loyalitas Pelanggan Berbasis Model RFM Terbobot dan Pelanggan Berbasis Preferensi Pembelian Produk

Hasil uji coba menunjukkan bahwa nilai optimum *F1-Measure* untuk kelompok pelanggan berdasarkan kedekatan jarak preferensi pembelian produk didapat pada nilai $k = 90$, sebesar 0,3705 (lihat tabel 12). Sedangkan untuk kelompok pelanggan berdasarkan nilai *RFM* terbobot, nilai optimum *F1-Measure* didapat pada nilai $k = 75$, sebesar 0,3727 (lihat tabel 13). Pengaruh tingkat loyalitas pelanggan melalui berbasis model *RFM* dapat dilihat dari perbandingan nilai metrik *F1-Measure* pada kondisi kelompok pelanggan berdasarkan kedekatan jarak nilai *RFM* dengan kondisi kelompok pelanggan berdasarkan kedekatan jarak yang dihitung dari preferensi pembelian produk oleh pelanggan selama periode analisis. Tabel 8 menunjukkan perbandingan nilai *F1-Measure* dari kedua kondisi tersebut dan membuktikan bahwa tingkat loyalitas pelanggan berbasis model *RFM* memberikan kontribusi nyata dalam meningkatkan kualitas rekomendasi produk. Gambar 3 menunjukkan visualisasi perbandingan nilai *F1-Measure* pada kondisi kelompok pelanggan berdasarkan kedekatan jarak nilai *RFM* dengan kondisi kelompok pelanggan berdasarkan kedekatan jarak yang dihitung dari preferensi pembelian produk. Hasil perhitungan nilai rata-rata metrik *F1-Measure* pada kelompok pelanggan berbasis model *RFM* terbobot mengalami peningkatan sebesar 0,17 % jika dibandingkan dengan nilai metrik *F1-Measure* pada kelompok pelanggan berdasarkan kedekatan jarak pembelian produk.

Tabel 8 Perbandingan Nilai *F1-Measure* pada Kelompok Pelanggan Berdasarkan Kedekatan Jarak Nilai *RFM* Terbobot Dengan Kelompok Pelanggan Berdasarkan Kedekatan Jarak Preferensi Pembelian Produk

k	F1-Measure kNN berdasarkan Pembelian Produk	F1-Measure kNN berdasarkan Nilai RFM Terbobot
10-NN	0.3485	0.3640
25-NN	0.3572	0.3678
50-NN	0.3643	0.3707
75-NN	0.3693	0.3727
90-NN	0.3705	0.3686
100-NN	0.3655	0.3533

110-NN	0.3598	0.3484
Rata-rata	0,3621	0,3638



Gambar 3 Grafik Perbandingan F1-Measure pada Data Kelompok Pelanggan Berdasarkan Kedekatan Jarak Nilai RFM Terbobot Dengan Data Kelompok Pelanggan Berdasarkan Kedekatan Jarak Preferensi Pembelian Produk

Dari hasil-hasil di atas, terlihat bahwa segmentasi dengan analisis RFM dan pembobotan dengan metode AHP memberikan perbaikan yang bermakna pada kondisi pemberian rekomendasi produk berdasarkan association analysis. Namun, kedua teknik ini tidak memberikan perbaikan performa yang berarti pada pemberian rekomendasi dengan teknik k-Nearest Neighbor. Meski demikian, dapat disimpulkan bahwa secara inheren segmentasi dengan RFM dan pembobotan dengan metode AHP memberikan informasi tentang kelompok pelanggan dan preferensi dari masing-masing kelompok, walaupun pada kasus pemberian rekomendasi informasi ini telah tertangkap secara otomatis oleh algoritma k-Nearest Neighbor.

5. SIMPULAN DAN SARAN

5.1 Simpulan

Berdasarkan pada nilai metrik *F1-Measure* hasil uji coba perbandingan kualitas rekomendasi produk, didapatkan hasil berikut :

- Perumusan aturan rekomendasi produk menggunakan teknik penggalian aturan asosiasi yang memanfaatkan algoritma *FP-Growth*, loyalitas pelanggan berbasis model RFM memberikan peningkatan sebesar 13 % terhadap kualitas rekomendasi produk. Jika diintegrasikan dengan metode pembobotan AHP, maka peningkatan sebesar 6% diperoleh terhadap kualitas rekomendasi produk.
- Perumusan aturan rekomendasi produk menggunakan teknik *collaborative filtering* yang memanfaatkan algoritma *k-nearest neighbor*, loyalitas pelanggan berbasis model RFM dan pembobotan AHP memberikan peningkatan sebesar 0,17% terhadap kualitas rekomendasi produk.

Dapat disimpulkan bahwa meskipun pada kasus rekomendasi dengan k-Nearest Neighbor pengetahuan mengenai kelompok pelanggan dan preferensinya telah terintegrasikan secara otomatis, analisis segmentasi pelanggan dengan metode RFM dan pembobotan nilai kepentingan variabelnya dengan AHP tetap memberikan informasi bermakna yang bermakna dan bermanfaat dalam melakukan kajian lebih lanjut mengenai karakteristik pelanggan.

5.2 Saran

Pada penelitian ini kajian mengenai segmentasi pelanggan telah dilakukan dengan contoh kasus satu industri. Untuk dapat memperluas penerapan dari kesimpulan yang dihasilkan, pada penelitian mendatang teknik yang telah dilakukan yaitu segmentasi dengan RFM dan pembobotan AHP dapat diterapkan pada perusahaan-perusahaan lain, sehingga dapat dilihat relevansinya dengan karakteristik industri bersangkutan.

6. DAFTAR RUJUKAN

- [1] Han, Jiawei., Kamber, Micheline., (2006), *Data Mining : Concept and Techniques Second Edition*, Morgan Kaufmann Publishers.
- [2] Miglautsch, J., (2000), *Thoughts On RFM Scoring*, Journal of Database Marketing 8 (1), pp. 67–72.
- [3] Miguéis, V. L., Camanho, A. S., Cunha, João Falcão e., (2012), *Customer data mining for lifestyle segmentation*, Expert Syst. Appl. 39(10): 9359-9366
- [4] Nugraheni, Y., (2011), *Data Mining dengan Metode Fuzzy Untuk Customer Relationship Management (CRM) pada Perusahaan Retail*, Program Pasca Sarjana Teknik Elektro, Univ. Udayana, Bali.
- [5] Tabaei, Zahwa., Fathian, M., (2012), *Using Customer lifetime Value Model for Product Recommendation: An Electronic Retailing Case Study*, International Journal of e-Education, e-Business, e-Management and e-Learning, Vol. 2, No. 1