

Terbit online pada laman web jurnal: <http://jurnal.iaii.or.id>

JURNAL RESTI

(Rekayasa Sistem dan Teknologi Informasi)

Vol. 3 No. 2 (2019) 100 - 105

ISSN Media Elektronik: 2580-0760

Sistem Rekomendasi Produk Menggunakan Model RFM, AHP dan *Ranked Clustering*

Siti Monalisa¹, Achmad Harpin Asrori², Fitra Kurnia³^{1,2,3} Sistem Informasi, Fakultas Sains dan Teknologi UIN Suska RiauEmail: ¹ siti.monalisa@uin-suska.ac.id, ² achmad.harpin.asrori@students.uin-suska.ac.id, ³ fitra.k@uin-suska.ac.id

Abstract

Monstreation is a business engaged in clothing convection, these business products are marketed online such as jackets and shirts for class, shirt and community clothing. The problem that occurs in this convection is the lack of product recommendation services to customers. Another problem is that if there are customers who order products that are not in accordance with their needs, the customer will rarely order products at Monstreation. The solution used is to provide services that match the characteristics of the customer, for example by giving product recommendations. Product recommendations are also needed considering this type of business is a business that has many business rivals. The steps taken in this study begin by collecting customer transaction data, then the data is transformed into RFM criteria data. After being transformed, the data is weighted using AHP, after that the RFM data is weighted then grouped / clustered. The grouping results are validated with DBI. From the experiments conducted it is known that the number of cluster 3 is the optimal number of clusters in product grouping. After it is ranked based on the value of the total weight. From the experiments conducted, it is known that the results of the 3 customer clusters, the customers who have the highest weight value are customers in cluster 1. The results of this study are a product recommendation that is an association of product history of customers who have a cluster similarity and a product recommendation information system.

Keywords: AHP, FCM, Competition, Recommendations, RFM, Convection Business

Abstrak

Monstreation adalah sebuah usaha yang bergerak dibidang konveksi pakaian, produk-produk usaha ini dipasarkan secara online seperti jacket dan kaos untuk kelas, baju angkatan dan komunitas. Konveksi ini belum memiliki rekomendasi produk kepada pelanggan sehingga bisa mengakibatkan kehilangan pelanggan dan juga pendapatan. Selain itu, transaksi pelanggan tidak digunakan untuk mendapatkan informasi berupa rekomendasi produk yang selalu dibeli oleh masing-masing pelanggan. Rekomendasi produk juga diperlukan mengingat jenis usaha ini adalah usaha yang memiliki banyak saingan bisnis. Solusi yang dihadirkan pada penelitian ini adalah dengan memberikan pelayanan yang sesuai dengan karakteristik pelanggan, misalnya dengan pemberian rekomendasi produk. Langkah-langkah yang dilakukan dalam penelitian ini dimulai dengan mengumpulkan data transaksi pelanggan, lalu data tersebut di transformasikan menjadi data kriteria RFM. Setelah di transformasikan maka data di bobotkan menggunakan AHP setelah itu data RFM terbobot kemudian dikelompokkan/clustering. Hasil pengelompokan divalidasi dengan DBI. Dari percobaan yang dilakukan diketahui bahwa jumlah cluster 3 merupakan jumlah cluster optimal dalam pengelompokan produk. Setelah itu diranking berdasarkan nilai jumlah bobotnya. Dari percobaan yang dilakukan diketahuilah pelanggan yang memiliki nilai bobot yang paling tinggi adalah pelanggan yang berada di cluster 1. Hasil dari penelitian ini adalah sebuah rekomendasi produk yang merupakan asosiasi dari riwayat produk dari pelanggan yang memiliki kesamaan cluster dan sebuah sistem informasi rekomendasi produk.

Kata kunci: AHP, FCM, Persaingan, Rekomendasi, RFM, Usaha Konveksi

© 2019 Jurnal RESTI

1. Pendahuluan

Monstreation adalah sebuah usaha yang bergerak dibidang konveksi pakaian. Usaha konveksi ini dirikan oleh Carson Arias pada tanggal 5 April 2015. Produk

produk usaha ini dipasarkan secara *online* melalui akun sosial media. Jenis produk yang di pasarkan seperti jacket dan kaos untuk kelas, baju angkatan, komunitas dan lain lain.

Diterima Redaksi : xx-xx-20xx | Selesai Revisi : xx-xx-20xx | Diterbitkan Online : xx-xx-20xx

Rekomendasi produk kepada pelanggan pada Monstreation ini diperlukan mengingat jenis usaha ini adalah usaha konveksi baju yang memiliki banyak saingan bisnis. Rekomendasi produk kepada konsumen merupakan salah satu cara untuk mengembangkan nilai pelanggan [1] dengan memanfaatkan data penjualan dari Monstreation sendiri.

Dari rekomendasi produk ini pihak Monstreation dapat merekomendasikan produk berdasarkan karakteristik pelanggan. Karakteristik pembelian pelanggan didapat dari analisa data historikal pembelian di masa lalu yang kemudian diolah agar memudahkan pelanggan untuk menentukan produk yang akan dibeli. Model yang digunakan dalam menganalisis pembelian pelanggan dimasa lalu adalah model RFM guna memprediksi perilaku pelanggan [2]. Model RFM terdiri dari Recency, Frekuensi dan Monetary [3] yang dikembangkan oleh [4]. Model RFM ini diklaster dengan menggunakan algoritma Fuzzy C-Means (FCM) dan metode validitas klaster menggunakan metode Davies Bouldin [5]. Algoritma ini memiliki kinerja yang lebih baik dibandingkan algoritma klasterisasi lain yaitu K-Means [6]. Selain itu, penelitian ini juga menggunakan Analytic Hierarchy Process (AHP) guna memberikan prioritas dalam memberikan penilaian yang terpenting pada model R, F dan M melalui pengisian survey [7] kepada manajer dan karyawan Monstreation.

Berdasarkan penelitian [8] mengenai Rekomendasi Produk Berdasarkan Loyalitas Pelanggan Menggunakan Integrasi Metode AHP Dan Teknik Penggalian Data dapat di ambil kesimpulan bahwa analisa loyalitas pelanggan berbasis model RFM dan pembobotan AHP memberikan peningkatan sebesar 0,17% terhadap kualitas rekomendasi produk. Metode FCM adalah metode yang lebih baik untuk melakukan *clustering* pada data *user knowledge modeling* dikarenakan nilai validitasnya lebih mendekati nilai 1 [9]

Berdasarkan penelitian [10] tentang Rekomendasi Pembelian Personal Komputer Dengan Metode *Ranked Clustering* dapat diambil kesimpulan bahwa pengolahan data menggunakan kombinasi algoritma AHP dan *K-Means* menghasilkan rekomendasi produk kepada pengguna yang lebih heterogen dibandingkan dengan rekomendasi produk dari data yang diolah hanya menggunakan algoritma AHP tanpa di-*cluster K-Means*. Hal ini menunjukkan bahwa proses *clustering* akan menghasilkan kaidah-kaidah asosiasi dengan kualitas yang lebih baik.

2. Metode Penelitian

Penelitian ini menggunakan beberapa tahapan yang akan dijelaskan sebagai berikut yaitu pertama, pengumpulan data menggunakan data penjualan Monstreation Pekanbaru.

Kedua, Setelah mendapatkan data yang diperlukan, dilakukan pembersihan data jika terdapat data yang tidak lengkap, ganda dan sebagainya. Ketiga, Selanjutnya data yang telah melalui tahapan pembersihan maka akan dilakukan transformasi data kedalam model RFM

Keempat, data yang telah ditransformasikan akan dilakukan normalisasi menggunakan algoritma min-max [7,11,12]. Kelima, data yang telah dinormalisasikan akan dilakukan pengklusteran dengan algoritma FCM. Keenam, dalam melakukan perangkungan data pelanggan, data yang telah dinormalisasikan akan dikalikan dengan bobot AHP. Selanjutnya dilakukan rekomendasi produk perkluster. Selanjutnya terakhir dibangun sistem rekomendasi produk menggunakan pemrograman PHP.

3. Hasil dan Pembahasan

Data yang digunakan pada penelitian ini untuk sistem informasi rekomendasi berasal dari data tiga tahun yakni data penjualan tahun 2015, 2016 dan 2017 berjumlah 538 kali transaksi dengan 16.206 produk terjual. Namun penelitian ini hanya menggunakan data 20 pelanggan sebagai contoh perhitungan.

Adapun data kriteria RFM dari 20 pelanggan yang digunakan ditunjukkan pada Tabel 1.

Tabel 1. Data Kriteria RFM

No	Nama Pelanggan	Jenis	R	F	M
1	SMAN Binsus Dumai	Hoodie Zipper	40	110	16.500.000
...
20	Megakom Komputer	Bomber Jacket	262	34	5.780.000

Selanjutnya dilakukan normalisasi data dengan menggunakan metode *Min Max Normalization* maka di dapatlah hasil yang ditunjukkan pada Tabel 2.

Tabel 2. Hasil Normalisasi Data

No	Nama Pelanggan	R X Bobot	F X Bobot	M X Bobot
1	SMAN Binsus Dumai	0,005	0,235	0,120
2	SMAN 9 Pekanbaru	0,008	0,118	0,062
3	SMP Cendana	0,090	0,202	0,067
4	SMA Cendana	0,110	0,307	0,126
5	Pesantren Babussalam	0,016	0,216	0,103
...
20	Megakom Komputer	0,037	0,053	0,031

Selanjutnya dilakukan pembobotan dengan algoritma *Analytic Hierarki Proses* (AHP) dalam menilai pengaruh kriteria *recency*, *frequency*, dan *monetary* terhadap operasional perusahaan serta dinotasikan

dengan wR , wF , dan wM . Bobot tersebut dikalikan dengan nilai kriteria model RFM.

Langkah pertama adalah membuat penilaian perbandingan berpasangan kriteria. Penilaian perbandingan berpasangan kriteriaditunjukkan pada Tabel 3.

Tabel 3. Perbandingan Berpasangan Kriteria

Kriteria	Recency	Frequency	Monetary
Recency	1/1	1/5	1/3
Frequency	5/1	1/1	2/1
Monetary	3/1	1/2	1/1

Tabel diatas akan diubah dalam bentuk desimal, hasil desimal dapat dilihat pada Tabel 4.

Tabel 4. Perbandingan Berpasangan Kriteria Desimal

Kriteria	Recency	Frequency	Monetary
Recency	1,00	0,200	0,33
Frequency	5,00	1,00	1,00
Monetary	3,00	0,50	1,00

Langkah selanjutnya adalah menormalisasi nilai setiap kolom. Hasil normalisasi nilai setiap kolom dapat dipahami dalam Tabel 5.

Tabel 5. Normalisasi Nilai Setiap Kolom

Kriteria	Recency	Frequency	Monetary
Recency	0,111	0,118	0,100
Frequency	0,556	0,588	0,600
Monetary	0,333	0,294	0,300

Selanjutnya adalah menjumlahkan nilai dari setiap baris yang telah di normalisasi, kemudian merata-ratakan nilai tersebut, nilai rata-rata dari setiap baris tersebut adalah nilai vektor *eigen*. Hasilnya dapat dilihat pada Tabel 6.

Tabel 6. Nilai Vektor *Eigen*

Kriteria	Vektor <i>Eigen</i>
Recency	0,110
Frequency	0,581
Monetary	0,309

Dari hasil diatas, maka disetiap kriteria memiliki nilai eigen yang diperoleh dari proses perhitungan, nilai eigen pada setiap kriteria tersebut akan dijadikan sebagai nilai pembobotan kriteria RFM, adapun hasil kali bobot dengan nilai kriteria RFM dapat dipahami pada Tabel 7.

Langkah selanjutnya adalah menjumlahkan nilai kriteria terbobot (WP) untuk masing masing produk. Adapun penjumlahan dapat dipahami sebagai berikut:

$$\sum WP = WR + WF + WM \quad (1)$$

Hasil penjumlahan nilai kriteria terbobot adalah pada Tabel 8.

Tabel 7. Hasil Kali Bobot Dengan Kriteria RFM

No	Nama Pelanggan	R X Bobot	F X Bobot	M X Bobot
1	SMAN Binsus Dumai	0,001	136,535	0,037
2	SMAN 9 Pekanbaru	0,001	68,558	0,019
3	SMP Cendana	0,010	117,362	0,021
4	SMA Cendana	0,012	178,367	0,039
5	Pesantren Babussalam	0,002	125,496	0,032
...	...			
20	Megakom Komputer	0,004	30,793	0,010

Tabel 8. Hasil Penjumlahan Nilai Kriteria Terbobot

No	Nama Pelanggan	WP
1	SMAN Binsus Dumai	0,361
2	SMAN 9 Pekanbaru	0,187
3	SMP Cendana	0,359
4	SMA Cendana	0,543
5	Pesantren Babussalam	0,335
...
20	Megakom Komputer	0,121

3.5 Pengelompokan Data RFM Terbobot

Data yang dikelompokan adalah data kriteria RFM terbobot dan jumlah nilai kriteria terbobot. Hal ini bertujuan untuk mencari aturan rekomendasi produk yang lebih heterogen. Metode pengelompokan yang digunakan adalah *Fuzzy C Means*. Berikut adalah langkah-langkah pengelompokan dengan *Fuzzy C Mean s*:

Langkah pertama untuk mengelompokan dengan FCM adalah menetapkan parameter, seperti dilihat pada Tabel 9.

Tabel 9. Parameter FCM

Parameter	Nilai Parameter
C	4
W	2
Maxiter	5
E	0.1
PO	100

Langkah selanjutnya adalah memberikan nilai sembarang dalam jangkauan 0 sampai 1 dengan jumlah untuk setiap baris/data adalah 1. Nilai sembarang dapat dipahami pada Tabel 10.

Tabel 10. Nilai u Awal *Random*/Sembarang

No	U1	U2	U3	U4
1	0,100	0,400	0,100	0,400
2	0,200	0,400	0,200	0,200
3	0,400	0,400	0,100	0,100
4	0,400	0,200	0,200	0,200
...
20	0,400	0,100	0,400	0,100

Langkah pertama adalah menghitung *centroid cluster* 1 pada iterasi pertama dengan cara memangkatkan nilai U1 dengan nilai pangkat (w), contohnya $(w) = (U1)^2 = (0,100)^2 = 0,010$. Kemudian nilai yang didapat dikalikan R Terbobot (WR) = $(0,010 \times 0,005) = 0,000$, lalu cara tersebut dilakukan dengan nilai F Terbobot (WF), M Terbobot (WM) dan WP. Hasilnya ditunjukkan pada Tabel 11. Lakukan hal yang sama untuk mencari *centroid cluster* 2 hingga 4.

Tabel 11. Hasil Cluster 1

No	U1^2	U1^2 *WR	U1^2 *WF	U1^2 *WM
1	0,010	0,000	0,002	0,001
2	0,040	0,000	0,005	0,002
3	0,160	0,014	0,032	0,011
4	0,160	0,018	0,049	0,020
...
20	0,160	0,006	0,008	0,005
Jumlah	1,590	0,076	0,264	0,127

Langkah selanjutnya adalah menghitung setiap jarak data ke *cluster/matriks pseudo-partition*. Berikut merupakan jarak data ke *cluster* dapat dipahami pada Tabel 12.

Tabel 12. Hasil Jarak Data Ke Cluster

No	Centroid 1	Centroid 2	Centroid 3	Centroid 4
1	0,113	0,064	0,207	0,188
2	0,125	0,162	0,042	0,046
3	0,086	0,078	0,180	0,166
4	0,297	0,261	0,397	0,382
...
20	0,212	0,256	0,111	0,129

Langkah selanjutnya adalah mencari nilai keanggotaan dalam matriks *pseudo-partition* untuk mendapatkan nilai U baru. Cara yang sama dilakukan untuk mendapatkan seluruh nilai U baru. Hasil nilai keanggotaan semua data dalam matriks *pseudo-partition* seperti dilihat pada Tabel 13.

Tabel 13. Hasil Nilai u Baru

NO	U1	U2	U3	U4
1	0,210	0,651	0,063	0,076
2	0,056	0,033	0,488	0,423
3	0,366	0,452	0,084	0,098
4	0,290	0,373	0,162	0,175
...
20	0,124	0,085	0,454	0,337

Langkah selanjutnya adalah menghitung nilai fungsi objektif dengan mengalikan nilai derajat keanggotaan dengan nilai U baru. Cara yang sama dilakukan untuk mendapatkan nilai fungsi objektif seperti yang ditunjukkan pada Tabel 14.

Tabel 14. Hasil Fungsi Objektif

NO	Cluster 1	Cluster 2	Cluster 3	Cluster 4
1	0,001	0,002	0,000	0,000
2	0,000	0,000	0,000	0,000
3	0,001	0,001	0,000	0,000
4	0,007	0,010	0,004	0,004
...
20	0,001	0,000	0,003	0,002
Jumlah	0,094	0,105	0,100	0,095
			P1=	0,394

Nilai fungsi objektif (P) adalah 0,394, Perubahan fungsi objektif $P0 - P1 = 100 - 0,394 = 99,606$. Perubahan ini menunjukkan bahwa nilai fungsi objektif ini masih di atas ambang batas yang didapat, maka proses pengelompokan dilanjutkan ke iterasi berikutnya, lakukan kembali langkah pertama dengan nilai U diambil dari nilai keanggotaan dalam matriks *pseudo-partition* pada iterasi pertama. Setelah mendapatkan nilai P yang lebih kecil dari ambang batas, pada kasus ini dilakukan 3 kali iterasi.

Nilai fungsi objektif (P) pada iterasi ke tiga adalah = 0,222. Perubahan fungsi objektif iterasi kedua ke fungsi objektif iterasi ketiga $P2 - P3 = 00,291 - 0,222 = 0,069$. Karena Nilai fungsi objektif (P) sudah lebih kecil daripada nilai epsilon maka proses dihentikan. Kemudian menentukan letak *cluster* dengan cara membandingkan ke empat *cluster*, nilai maksimum adalah sebagai penentu letak *cluster*. Hasil *cluster* yang didapat adalah pada Tabel 15.

Tabel 15. Hasil Fungsi Objektif

No	Nama Pelanggan	U1	...	U4	Max	C
1	SMAN Binsus Dumai	0,749	...	0,044	0,749	1
2	SMAN 9 Pekanbaru	0,056	...	0,645	0,645	4
3	SMP Cendana	0,669	...	0,090	0,669	1
4	SMA Cendana	0,278	...	0,028	0,670	2
5	Pesantren Babussalam	0,671	...	0,087	0,671	1
...
20	Megakom Komputer	0,002	...	0,538	0,538	4

3.5 Validasi Jumlah Cluster

Setelah data dikelompokkan maka langkah selanjutnya adalah mengevaluasi hasil analisis *cluster* sehingga ditemukanlah jumlah *cluster* terbaik dalam mengelompokkan produk. Algoritma validasi yang digunakan adalah IDB, adapun langkah langkah perhitungannya sebagai berikut:

Langkah pertama yang di lakukan adalah mencari titik pusat *cluster* akhir dengan cara merata-ratakan seluruh data pada setiap *cluster*, perhitungan dapat dipahami pada Tabel 16.

Tabel 16. Pusat Cluster 1

No	Nama Pelanggan	R Terbobot	F Terbobot	M Terbobot	WP
1	SMAN 9 Pekanbaru	0,008	0,118	0,062	0,187
2	SMAN 5	0,072	0,065	0,038	0,175
Pusat Cluster:		0,043	0,131	0,065	0,239

Langkah selanjutnya adalah mencari nilai *Sum of square within cluster* (SSW). Cara nya adalah dengan menghitung jarak antara masing masing data ke pusat

cluster menggunakan rumus *Eclidean Distance*, kemudian jarak tersebut di rata-ratakan, setelah mencari SSW kemudian mencari SSB, R-Max dan IDB. Adapun hasil IDB di tabel 17.

Tabel 17. Hasil IDB

Jumlah Cluster	Nilai IDB
2	29,450
3	7,034
4	40,284

3.7 Rekomendasi Produk

Adapun rekomendasi produk dapat dipahami sebagai berikut : terdapat dua hal yang di lakukan yaitu merangking *cluster* berdasarkan atribut WP, setelah di rangking kemudian di rekomendasikan assosiasi produk yang pernah dibeli pelanggan pada tiap-tiap *cluster*.

1. Perangkingan Cluster

Pada tahap ini dilakukan pengambilan rekomendasi produk dilakukan dengan merangking *cluster* berdasarkan rata-rata atribut WP (jumlah kriteria terbobot) tiap-tiap *cluster*, perangkingan dilakukan dari tingkat bobot tertinggi dari masing-masing *cluster*. Berikut merupakan contoh rangking pada Tabel 18.

Tabel 18. Rangking Nilai WP Setiap Cluster

NO	Cluster	Rata-rata Nilai WP	Rangking
1	C1	0,181	2
2	C2	0,471	1
3	C3	0,066	3

Dari tabel diatas dapat diambil kesimpulan bahwa *cluster* 2 mempunyai nilai WP yang paling tinggi, hal ini berarti bahwa pelanggan yang berada di *cluster* 2 merupakan pelanggan-pelanggan yang paling loyal dibandingkan pelanggan yang berada di *cluster* 1 dan 3.

2. Rekomendasi Produk

Adapun contoh rekomendasi produk pada *Cluster* 1 dapat dilihat pada Tabel 19.

Tabel 19. Riwayat Produk Cluster 1

No	Nama Pelanggan	WP	Riwayat Produk
1	SMAN 9 Pekanbaru	0.187	Hoodie Zipper, Blazzer
2	SMAN 5	0.175	Bomber Jacket

Dari tabel diatas dapat diambil kesimpulan bahwa terdapat 2 pelanggan dengan 3 jenis produk yang dapat diasosiasikan untuk di rekomendasikan pada pelanggan yang berada di *cluster* 1 tersebut, adapun 2 pelanggan dan 3 jenis produk rekomendasi tersebut dapat dilihat pada Tabel 20.

Tabel 20. Riwayat Produk Cluster 1

No	Nama Pelanggan	Rekomendasi Produk
1	SMAN 9 Pekanbaru	Hoodie Zipper, Blazer
2	SMAN 5	Bomber Jacket

3.8 Tampilan Sistem Informasi Rekomendasi Produk

Sistem informasi ini digunakan oleh Admin. Admin akan melakukan penginputan data pelanggan dan produk untuk mendapatkan atribut pada model RFM. Tampilan penginputan data tersebut di tunjukkan pada Gambar 1.



Gambar 1. Tampilan Sistem Form input data RFM

Halaman admin untuk meng-input-kan data pelanggan dan produk untuk ditransformasikan menjadi kriteria RFM ditunjukkan pada Gambar 1. Hasil data yang telah ditransformasikan ditunjukkan pada Gambar 2.

No	Nama Pelanggan	Recency	Frequency	Monetary
1	SMAN Binjai Dumai	40	110	Rp. 16.500.000
2	SMAN 9 Pekanbaru	58	61	Rp. 9.400.000
3	SMP Cendana	626	96	Rp. 10.100.000
4	SMA Cendana	93	140	Rp. 17.170.000
5	Pesantren Babussalam	43	102	Rp. 14.660.000
6	SMP Muhammadiyah	627	58	Rp. 8.700.000
7	SMA Dharma Loka	125	137	Rp. 20.010.000
8	FMIPA UR	91	254	Rp. 39.140.000
9	Benteng Mas	62	13	Rp. 2.210.000
10	SPS	70	21	Rp. 4.620.000

Gambar 2. Tampilan Sistem Data RFM

Data pelanggan yang telah ditransformasikan ke bentuk RFM maka dilakukan normalisasi. Hasil normalisasi data pelanggan tersebut dikluster dengan algoritma FCM menggunakan metode validasi *Daives Bouldin Index*. Jumlah kluster yang terbaik digunakan untuk tahapan selanjutnya. Data pelanggan yang telah di kluster akan dikalikan dengan bobot AHP. Halaman peng-input- tingkat kepentingan sebagai bahan pembobotan untuk kriteria RFM ditunjukkan pada Gambar 3 dan hasil pembobotannya ditunjukkan pada Gambar 4. Tampilan hasil kluster data pelanggan ditunjukkan pada Gambar 5. Tampilan rekomendasi produk untuk kluster 1 ditunjukkan pada Gambar 6.

Gambar 3. Tampilan Sistem *Input* data pembobotan

Hasil Bobot

Kriteria	Bobot
Recency	0.110
Frequency	0.581
Monetary	0.309

Nilai CR 0.0068965517241379

HASIL =KONSISTEN

Gambar 4. Tampilan Sistem Hasil Pembobotan AHP.

CLUSTER 1

NO	Nama Pelanggan	R Terbobot	F Terbobot	M Terbobot	WP
1	SMP Muhammadiyah	0.110	0.110	0.056	0.276

CLUSTER 2

NO	Nama Pelanggan	R Terbobot	F Terbobot	M Terbobot	WP
1	SMP Muhammadiyah	0.110	0.110	0.056	0.276

CLUSTER 3

NO	Nama Pelanggan	R Terbobot	F Terbobot	M Terbobot	WP
1	SMAN 5	0.088	0.065	0.038	0.191
2	SMAN 9 Pekanbaru	0.009	0.117	0.061	0.187
3	SCITO 33	0.066	0.060	0.036	0.162
4	Megakom Komputer	0.045	0.053	0.031	0.129
5	Divergent	0.067	0.019	0.013	0.099
6	FOS4	0.025	0.024	0.014	0.063
7	IPS Team	0.058	0.000	0.000	0.058
8	SPS	0.011	0.021	0.022	0.054
9	Internal Audit Forestry	0.038	0.007	0.004	0.049
10	Flashsoft	0.026	0.005	0.003	0.034
11	Benteng Mas	0.010	0.002	0.002	0.014

Gambar 5. Tampilan Sistem Hasil *clustering*

REKOMENDASI CLUSTER 1

No	Nama Pelanggan	Riwayat Produk
1	SMAN 5	- Bomber Jacket - Blazer - Hoodie Zipper
2	SMAN 9 Pekanbaru	
3	SCITO 33	
4	Megakom Komputer	
5	Divergent	
6	FOS4	
7	IPS Team	
8	SPS	
9	Internal Audit Forestry	
10	Flashsoft	
11	Benteng Mas	

Gambar 6. Tampilan Sistem Rekomendasi produk

4. Kesimpulan

Berdasarkan hasil penelitian dapat diketahui bahwa dengan Model RFM, AHP dan pengelompokan *Fuzzy C-Means* dapat digunakan untuk merekomendasikan

produk pada Montreatment Konveksi Pekanbaru. Rekomendasi produk kepada pelanggan Montreatment Konveksi Pekanbaru yaitu berdasarkan nilai atribut WP (Jumlah kriteria terbobot) yang dimiliki oleh masing masing pelanggan. Dilakukan percobaan perankingan pelanggan sebanyak 3 *cluster*, maka dari hasil percobaan tersebut maka pelanggan yang menjadi ranking 1 atau yang paling loyal adalah pelanggan yang berada di *cluster* 1 karena mempunyai rata-rata nilai WP yang paling tinggi. Penggunaan IDB dapat memvalidasi hasil *clustering* dari proses FCM. Dilakukan percobaan perhitungan IDB dengan jumlah *cluster* 2,3 dan 4. Maka jumlah *cluster* optimal yang dapat digunakan untuk merekomendasikan produk adalah percobaan dengan jumlah *cluster* 3 karena memiliki nilai IDB yang paling rendah. Pada sistem, percobaan IDB otomatis terjadi karena input jumlah *cluster* pada parameter pengelompokan FCM.

Daftar Rujukan

- [1] Ngai EWT, Xiu L, Chau DCK. Application of data mining techniques in customer relationship management: A literature review and classification. *Expert Systems with Applications* [Internet]. 2009;36(2 PART 2):2592–602. Available from: <http://dx.doi.org/10.1016/j.eswa.2008.02.021>
- [2] Khajvand M, Zolfaghar K, Ashoori S, Alizadeh S. Estimating customer lifetime value based on RFM analysis of customer purchase behavior: Case study. *Procedia Computer Science* [Internet]. 2011;3:57–63. Available from: <http://dx.doi.org/10.1016/j.procs.2010.12.011>
- [3] Buttle F, Stan M. *Customer Relationship Management*. Third edit. Butterworth-Heinemann; 2015.
- [4] Arthur M H. *Strategic database marketing*. Chicago: Probus Publishing Co. 1994.
- [5] Thomas JCR, Peñas MS, Mora M. New Version of Davies-Bouldin Index for Clustering Validation Based on Cylindrical Distance. In: *Proceedings - International Conference of the Chilean Computer Science Society, SCCC*. 2017.
- [6] Ramadhan A, Efendi Z. Perbandingan K-Means dan Fuzzy C-Means untuk Pengelompokan Data User Knowledge Modeling. 2017;18–9.
- [7] Parvaneh A, Abbasimehr H, Tarokh MJ. Integrating AHP and data mining for effective retailer segmentation based on retailer lifetime value. *Journal of Optimization in Industrial Engineering*. 2012;5(11):25–31.
- [8] Kurniawaty Dita. Dkk., 2014. Rekomendasi Produk Berdasarkan Loyalitas Pelanggan Menggunakan Integrasi Metode AHP Dan Teknik Penggalian Data : Studi Kasus CV.XYZ. *Inovasi dalam Desain dan Teknologi Seminar Nasional Sistem Informasi Indonesia*.
- [9] Triyanto Wiwit Agus., 2014. Association Rule Mining Untuk Penentuan Rekomendasi Promosi Produk. *Jurnal SIMETRIS*, Vol 5 No 2.
- [10] Shabir Fadil dan Abdul Rachman M., 2016. Rekomendasi Pembelian Personal Komputer Dengan Metode Ranked Clustering. *Jurnal Ilmiah ILKOM* Volume 8 Nomor 2.
- [11] Thorleuchter D, Poel D Van Den, Prinzie A. *Expert Systems with Applications Analyzing existing customers' websites to improve the customer acquisition process as well as the profitability prediction in B-to-B marketing*.
- [12] Han J, Kamber M, Pei J. *Data Mining: Concepts and Techniques* [Internet]. San Francisco, CA, itd: Morgan Kaufmann. 2012. 745