

Fuzzy C-Mean untuk Mengcluster Pemain Football FIFA (Studi Kasus: Data Kaggle)

Mohammad Afan¹, Retno Wardhani², Nur Nafi'iyah³

^{1,2,3} Program Studi Teknik Informatika, Fakultas Teknik,
Universitas Islam Lamongan
Jalan Veteran Nomor 53A Lamongan
[2retzno@yahoo.com](mailto:retzno@yahoo.com), [3mynaff26@gmail.com](mailto:mynaff26@gmail.com)

Abstrak

Dari kumpulan data yang ada di dunia internet, kami ingin melakukan pengelolahan. Tujuan pengelolahan data yang ada di internet khususnya kaggle adalah untuk mengetahui bagaimana proses clustering serta bagaimana menerapkan algoritma fuzzy c-mean. Fuzzy c-mean digunakan untuk mengcluster dan mendapatkan nilai centroid dari masing-masing cluster. Hasil dari nilai centroid masing-masing cluster digunakan untuk mengelompokkan data baru atau dataset itu sendiri. Kami menggunakan dataset kaggle FIFA Football untuk dicluster menjadi 2 dan 3 kelompok. Algoritma fuzzy c-mean diimplementasikan untuk mencluster data sebanyak 2499 baris dengan 46 variabel. Tool yang digunakan untuk mengolah data adalah matlab.

Kata kunci—FIFA Fottbal, Clustering, Fuzzy C-mean, Matlab

Abstract

From the data set in the internet world, we want to do the management. The purpose of managing existing data on the internet especially Kaggle is to find out how the clustering process is and how to apply the c-mean fuzzy algorithm. Fuzzy c-mean is used to cluster and get the centroid value of each cluster. The results of the centroid value of each cluster are used to group new data or the dataset itself. We use the FIFA Football Kaggle dataset to cluster into 2 and 3 groups. Fuzzy c-mean algorithm is implemented to cluster data with 2499 rows with 46 variables. The tool used to process data is matlab.

Keywords—FIFA Fottbal, Clustering, Fuzzy C-mean, Matlab

1. PENDAHULUAN

Clustering merupakan mengelompokkan data sesuai dengan karakteristik yang sama. Clustering dapat digunakan untuk mengkluster data, ataupun mengkluster citra. Salah satu contoh penelitian terkait mengklaster data citra adalah penelitian Nur Nafi'iyah. Melakukan clustering citra untuk mengubah citra grayscale ke bentuk biner. Di mana proses clustering menggunakan algoritma SOM. Setiap intupan piksel dilatih untuk menghasilkan nilai bobot, dan bias. Dari bobot dan bias hasil latih digunakan untuk mengubah citra ke bentuk biner (Nafi'iyah, 2015). Selain digunakan untuk mengkluster data citra, algoritma SOM juga digunakan untuk mengkluster keahlian mahasiswa Teknik Informatika Universitas Islam Lamongan (Nafi'iyah, *Clustering Keahlian Mahasiswa dengan SOM (Studi Khusus: Teknik Informatika Unisla)*, 2015).

Di mana algoritma SOM digunakan untuk mengelompokkan keahlian mahasiswa menjadi 4 jurusan diantaranya keahlian informatika/logika, *software develop/engginner*, manajemen *database*, dan *networking/infrastuktur* dengan akurasi 82%. Variabel yang digunakan untuk mengelompokan 4 keahlian mahasiswa Teknik Informatika, yaitu: kalkulus 1, kalkulus 2, statistik probabilitas, matematika diskrit, metode numerik, logika matematika, algoritma pemrograman 1, algoritma pemrograman 2, pemrograman visual, pemrograman berorientasi objek, pemrograman internet, rekayasa perangkat lunak, analisa desain berorientasi objek, proyek perangkat lunak, sistem digital, organisasi dan arsitektur komputer, jaringan komputer, struktur data, basis data 1, basis data 2.

Sebagian besar *clustering* digunakan untuk mengelompokkan data yang berupa number atau angka. Akan tetapi tidak hanya data angka, *clustering* juga digunakan untuk mengelompokkan data *text* ataupun citra. Berikut beberapa penelitian terkait pengelompokan data berupa angka. Penelitian Adi Suryaputra terkait mengklaster data *bandwith* internet. Proses *clustering* menggunakan algoritma Fuzzy C-mean dan Fuzzy C-mean berdasarkan pemilihan fitur yang berkorelasi. Untuk memilih fitur yang berkorelasi menggunakan metode *correlation based feature selection*. Fitur-fitur yang dipilih diantaranya: *flow metrics*, *packet inter-arrival time*, *size of TOP/IP control fields*, *total packets*, *payload size*, *effective bandwidth based upon entropy*, *ranked list of top-ten*, dan lainnya. Hasil akurasi dalam mengkluster data terdapat perbedaan, jika menggunakan Fuzzy C-mean saja akurasinya 83,73%. Sedangkan jika menggunakan pemilihan korelasi fitur hasil *clustering* akurasinya 88,10% (Adi Suryaputra P, Febriliyan Samopa, Bekti Cahyo Hindayanto, 2014).

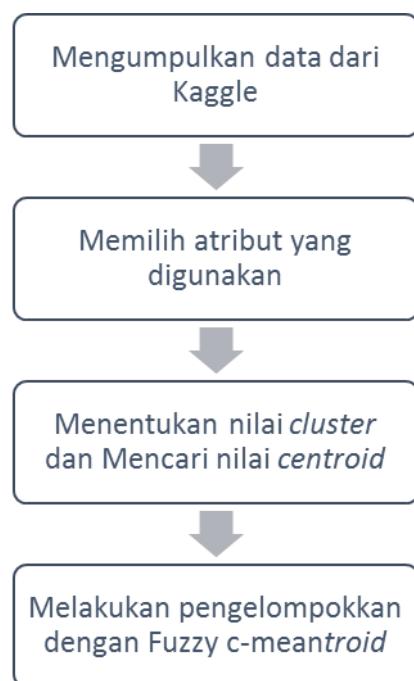
Penelitian lainnya yang terkait pengelompokan data numerik adalah Pengelompokan Pasar. Di mana melakukan segmentasi pasar agar dapat mengetahui perilaku konsumen dan bagaimana daya minat membeli konsumen. Tujuan penelitian melakukan segmentasi pasar untuk dapat memudahkan membuat strategi pemasaran. Atribut yang digunakan untuk mensegmentasi pasar adalah *recency*, *frequency* dan *monetary*. Proses *clustering* menggunakan algoritma FCM dan *Fuzzy Subtractive Clustering* dengan *tool* matlab (Titus Kristanto, Rachman Arief, 2013). Penelitian lain yang terkait *clustering* data numerik nilai siswa dan mahasiswa adalah (Tb. Ai Munandar, Wahyu Oktri Widyarto, Harsiti, 2013), (Nelson Butarbutar, Agus Perdana Windarto, Dedi Hartama, Solikhun, 2016), (Cary Lineker Simbolon, Nilamsari Kusumastuti, Beni Irawan, 2013). Ketiga penelitian tersebut terkait mengelompokkan nilai baik siswa ataupun mahasiswa. Penelitian Ali Munandar mengolah data nilai mahasiswa untuk mengelompokkan konsestrasi jurusan mahasiswa. Di mana terdapat 3 kelompok, yaitu: konsentrasi multimedia, konsentrasi web, dan konsentrasi pemrograman. Variabel yang digunakan untuk mengelompokkan adalah pemrograman internet, algoritma pemrograman, pemrograman terstruktur, komunikasi data, struktur data, matematika diskrit, IP semester 1, IP semester 2, IP semester 3, dan IP semester 4. Penelitian lainnya yang mengelompokkan nilai mahasiswa adalah Cary Lineker, yaitu mengelompokkan lulusan mahasiswa Matematika Universitas Tangjungpura berdasarkan IPK dan massa studi. Pengelompokan sebanyak 4 kelompok, dengan kelompok 1 IPK 3.15 massa studi 5.09 tahun, kelompok 2 IPK 2.88 massa studi 7.32 tahun, kelompok 3 IPK 3.48 massa studi 4.37 tahun, dan kelompok ke-4 IPK 2.89 massa studi 5.91 tahun. Hasil penelitian Cary menunjukkan kelompok ke-4 merupakan kelompok yang paling banyak dengan jumlah lulusan 33 mahasiswa. Penelitian lain terkait pengelompokan, yaitu Nelson Butarbutar dalam mengkluster nilai siswa untuk melihat prestasi akademik. *Clustering* siswa berdasarkan nilai rata-rata raport yang

dikelompokkan menjadi 3, yaitu kelompok ke-1 nilai rata-rata lebih dari sama dengan 7.24, kelompok ke-2 nilai rata-rata antara 6-7.24, dan kelompok ke-3 nilai rata-rata kurang dari sama dengan 4. Dari ketiga penelitian di atas (Tb. Ai Munandar, Wahyu Oktri Widyarto, Harsiti, 2013), (Nelson Butarbutar, Agus Perdana Windarto, Dedi Hartama, Solikhun, 2016), (Cary Lineker Simbolon, Nilamsari Kusumastuti, Beni Irawan, 2013) menggunakan algoritma *Fuzzy C-means*.

Dari kondisi penelitian sebelumnya yang melakukan *clustering* dengan menggunakan metode *fuzzy C-mean*. Maka kami ingin membuat *clustering* pemain football FIFA data dari *Kaggle* dengan algoritma *Fuzzy C-mean*.

2. METODE PENELITIAN

Alur penelitian ini seperti Gambar 1.



Gambar 1. Langkah Penelitian

Data diambil dari dataset Kaggle FIFA football. Data terdapat puluhan ribu variabel. Akan tetapi agar dapat digunakan untuk mengelompokkan data pemain football FIFA kami hanya menggunakan variabel yang berupa number/angka seperti Tabel 1. Variabel yang digunakan untuk pengelompokan hanya 46 variabel, diambil data yang number. Data yang digunakan hanya 2499 baris dari total *dataset* 18205 baris.

Tabel 1. Variabel yang Digunakan Mengelompokkan

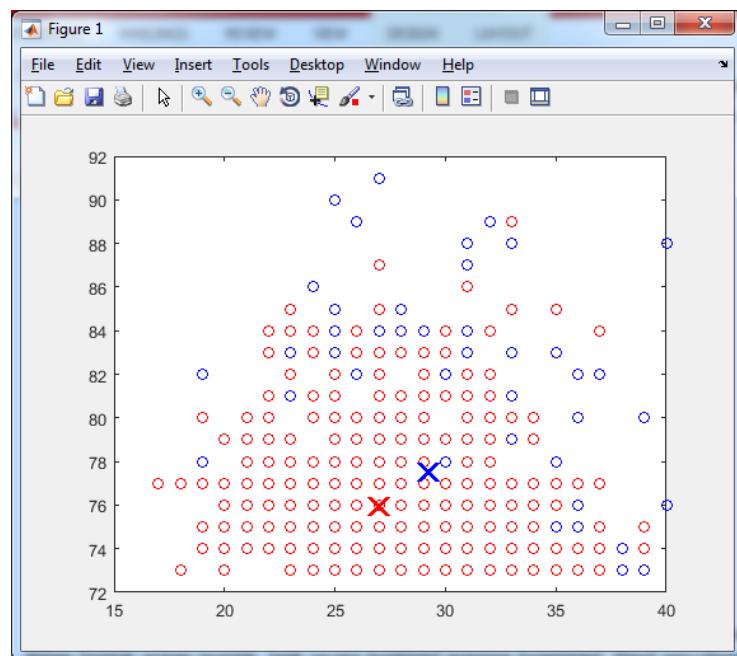
Nomor	Nama Variabel
1	Age
2	Overall
3	Potential

Nomor	Nama Variabel
4	<i>Value</i>
5	<i>Wage</i>
6	<i>Special</i>
7	<i>International Reputation</i>
8	<i>Wea Foot</i>
9	<i>Sill oves</i>
10	<i>Jersey Nuber</i>
11	<i>Weight</i>
12	<i>Crossing</i>
13	<i>Finishing</i>
14	<i>HeadingAccuracy</i>
15	<i>ShortPassing</i>
16	<i>Volleyes</i>
17	<i>Dribbling</i>
18	<i>Curve</i>
19	<i>FAccuracy</i>
20	<i>LongPassing</i>
21	<i>BallControl</i>
22	<i>Acceleration</i>
23	<i>SprintSpeed</i>
24	<i>Agility</i>
25	<i>Reactions</i>
26	<i>Balance</i>
27	<i>ShotPower</i>
28	<i>Juping</i>
29	<i>Staina</i>
30	<i>Strength</i>
31	<i>LongShots</i>
32	<i>Aggression</i>
33	<i>Interceptions</i>
34	<i>Positioning</i>
35	<i>Vision</i>
36	<i>Penalties</i>
37	<i>Coposure</i>
38	<i>aring</i>
39	<i>StandingTacle</i>
40	<i>SlidingTacle</i>
41	<i>GDivining</i>
42	<i>GHandling</i>
43	<i>Gicing</i>
44	<i>GPositioning</i>

Nomor	Nama Variabel
45	<i>GReflexes</i>
46	<i>Release Clause</i>

3. HASIL DAN PEMBAHASAN

Kami melakukan ujicoba untuk mengelompokkan data, ujicoba yang pertama menggunakan 3 kelompok, hasil pengelompokan seperti Gambar 2. Dalam melakukan *clustering* terjadi 43 iterasi, hasil nilai *centroid* dari ke-3 *cluster* dalam Tabel 2.

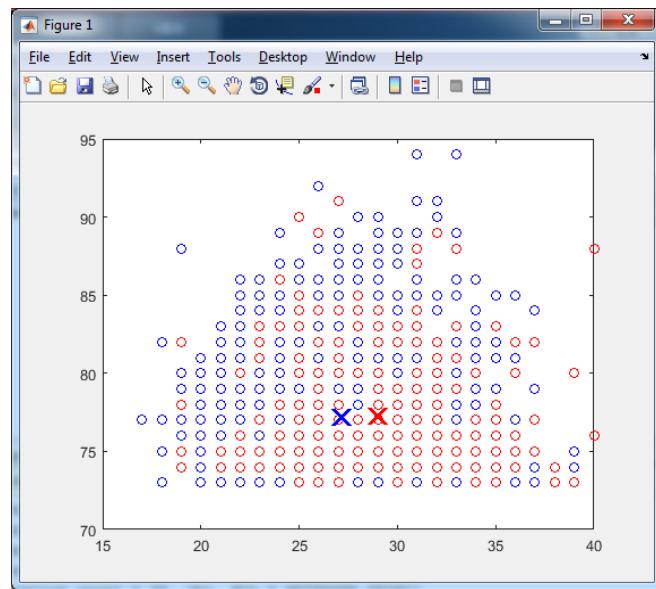


Gambar 2. Hasil Pengelompokan dengan 3 *Cluster*

Tabel 2. Nilai Centroid dari 3 *Cluster*

1	29.22338	26.9811	27.26395
2	77.53085	75.94702	77.84672
3	79.16544	78.32336	79.73092
4	19.59631	11.59967	14.34663
5	30.32982	30.60675	44.60566
6	1227.774	1795.971	2008.951
7	1.607041	1.423752	1.754507
8	2.643474	3.101886	3.315345
9	1.053505	2.73613	3.282717
10	13.95017	15.43923	15.26503
11	185.79	171.5422	163.9441
12	16.1266	57.23928	71.10886

13	13.87633	54.36986	63.87622
14	17.7548	67.83238	62.93703
15	32.80527	70.12443	76.78495
16	14.66123	51.31113	62.73651
17	16.84487	65.8087	75.63402
18	16.69641	55.30667	70.30246
19	15.69514	48.75494	63.87078
20	31.74054	62.33278	71.65342
21	24.14213	70.58047	77.50877
22	46.16654	67.41213	73.74782
23	46.56541	68.83792	72.97019
24	48.66805	66.06196	74.64847
25	72.92337	72.37305	75.79947
26	44.66877	63.58191	72.77258
27	25.62106	66.16312	74.87853
28	66.6016	69.6374	69.79471
29	36.14463	70.34594	77.69284
30	67.93701	72.9303	68.89548
31	15.13628	56.01538	69.74768
32	32.46932	67.5856	70.75619
33	22.57363	56.08019	63.85807
34	13.86278	58.80638	70.65099
35	47.09278	60.04875	72.45128
36	22.70397	55.98013	63.81204
37	57.35623	70.82917	74.83544
38	19.46013	56.51421	62.51521
39	17.13813	56.5284	63.71419
40	16.87088	53.41207	60.33252
41	75.01121	10.79921	10.66317
42	72.0218	10.83592	10.73952
43	68.32055	10.75289	10.75599
44	73.45326	10.789	10.72763
45	76.01938	10.81893	10.61373
46	22.51183	17.46339	24.77499



Gambar 3. Hasil *Clustering 2 Cluster*

Ujicoba yang kedua menggunakan 2 kelompok, hasil pengelompokan seperti Gambar 3. Dalam melakukan *clustering* terjadi 33 iterasi, hasil nilai centroid dari ke-2 *cluster* dalam Tabel 3.

Tabel 3. Nilai Centroid Hasil 2 *Cluster*

	<i>Cluster 1</i>	<i>Cluster 2</i>
1	27.15065	28.98279
2	77.18029	77.276
3	79.24048	79.00501
4	13.26384	26.45208
5	40.10303	31.67624
6	1935.871	1305.175
7	1.641018	1.593409
8	3.254964	2.682281
9	3.128763	1.261026
10	15.56202	13.6995
11	165.9521	185.2252
12	66.79992	20.65524
13	61.52523	17.91943
14	64.27171	28.55112
15	74.55304	39.03733
16	59.49521	18.34969
17	72.90824	23.2227
18	65.76498	20.75679
19	59.0513	19.30962

	<i>Cluster 1</i>	<i>Cluster 2</i>
20	68.29436	36.9498
21	75.47289	31.41837
22	72.21341	47.9894
23	72.10888	48.86454
24	72.43539	49.19596
25	74.61986	72.69364
26	70.17036	45.8475
27	72.20178	31.38628
28	69.61635	67.20539
29	75.05112	41.67885
30	69.72244	70.52476
31	65.59986	19.31421
32	68.85929	40.60445
33	59.49776	31.59733
34	67.46687	18.52909
35	68.67186	46.97305
36	61.5678	26.82992
37	73.50109	59.6862
38	58.93592	29.07685
39	59.44294	27.41744
40	56.08409	26.65801
41	10.66721	63.00146
42	10.73577	60.49527
43	10.74126	57.56953
44	10.68731	61.75507
45	10.63684	63.79652
46	22.33122	25.3111

Hasil pengelompokan dengan menggunakan 2 *cluster* ataupun 3 *cluster* dalam Tabel 4.

Tabel 4. Hasil Pengelompokan

Data	2- <i>Cluster</i>	3- <i>Cluster</i>
1	<i>Cluster 1</i>	<i>Cluster 2</i>
2	<i>Cluster 1</i>	<i>Cluster 2</i>
3	<i>Cluster 1</i>	<i>Cluster 2</i>
4	<i>Cluster 1</i>	<i>Cluster 2</i>
5	<i>Cluster 1</i>	<i>Cluster 2</i>
6	<i>Cluster 1</i>	<i>Cluster 2</i>
7	<i>Cluster 1</i>	<i>Cluster 2</i>
8	<i>Cluster 1</i>	<i>Cluster 2</i>
9	<i>Cluster 1</i>	<i>Cluster 2</i>

Data	2-Cluster	3-Cluster
10	<i>Cluster 1</i>	<i>Cluster 2</i>
11	<i>Cluster 1</i>	<i>Cluster 2</i>
12	<i>Cluster 1</i>	<i>Cluster 2</i>
13	<i>Cluster 1</i>	<i>Cluster 2</i>
14	<i>Cluster 1</i>	<i>Cluster 2</i>
15	<i>Cluster 1</i>	<i>Cluster 2</i>
16	<i>Cluster 1</i>	<i>Cluster 2</i>
17	<i>Cluster 1</i>	<i>Cluster 2</i>
18	<i>Cluster 1</i>	<i>Cluster 2</i>
19	<i>Cluster 1</i>	<i>Cluster 2</i>
20	<i>Cluster 1</i>	<i>Cluster 2</i>
21	<i>Cluster 1</i>	<i>Cluster 2</i>
22	<i>Cluster 1</i>	<i>Cluster 2</i>
23	<i>Cluster 1</i>	<i>Cluster 2</i>
24	<i>Cluster 1</i>	<i>Cluster 2</i>
25	<i>Cluster 1</i>	<i>Cluster 2</i>
26	<i>Cluster 1</i>	<i>Cluster 2</i>
27	<i>Cluster 1</i>	<i>Cluster 2</i>
28	<i>Cluster 1</i>	<i>Cluster 2</i>
29	<i>Cluster 1</i>	<i>Cluster 2</i>
30	<i>Cluster 1</i>	<i>Cluster 2</i>
31	<i>Cluster 1</i>	<i>Cluster 2</i>
32	<i>Cluster 1</i>	<i>Cluster 2</i>
33	<i>Cluster 1</i>	<i>Cluster 2</i>
34	<i>Cluster 1</i>	<i>Cluster 2</i>
35	<i>Cluster 1</i>	<i>Cluster 2</i>
36	<i>Cluster 1</i>	<i>Cluster 2</i>
37	<i>Cluster 1</i>	<i>Cluster 2</i>
38	<i>Cluster 1</i>	<i>Cluster 2</i>
39	<i>Cluster 1</i>	<i>Cluster 2</i>
40	<i>Cluster 2</i>	<i>Cluster 1</i>
41	<i>Cluster 1</i>	<i>Cluster 2</i>
42	<i>Cluster 1</i>	<i>Cluster 2</i>
43	<i>Cluster 1</i>	<i>Cluster 2</i>
44	<i>Cluster 1</i>	<i>Cluster 2</i>
45	<i>Cluster 1</i>	<i>Cluster 2</i>
46	<i>Cluster 1</i>	<i>Cluster 2</i>
47	<i>Cluster 1</i>	<i>Cluster 2</i>
48	<i>Cluster 1</i>	<i>Cluster 2</i>
49	<i>Cluster 1</i>	<i>Cluster 2</i>
50	<i>Cluster 1</i>	<i>Cluster 2</i>

4. KESIMPULAN

Dari kegiatan di atas mulai dari memilih variabel dan mengelompokkan data. Maka kesimpulan yang dapat disampaikan adalah proses *clustering* baik menggunakan 2 kelompok ataupun 3 kelompok cukup baik. Dilihat dari hasil *cluster* memang terdapat perbedaan, karena setiap kita melakukan uji coba untuk mencari nilai centroid akan dihasilkan nilai random. Kegiatan *clustering* ini menggunakan *tool* matlab dan fungsi *fuzzy c-mean* matlab.

5. SARAN

Dapat mengimplementasikan *fuzzy c-mean* untuk mengcluster data yang lain dari Kaggle dan kesemua dataset harus diolah serta digunakan secara tepat.

DAFTAR PUSTAKA

- Adi Suryaputra P, Febriliyan Samopa, Bekti Cahyo Hindayanto. (2014). *Klasterisasi dan Analisis Trafik Internet Menggunakan Fuzzy C Mean Dengan Ekstraksi Fitur Data*. *Jurnal Informatika*, 33-39.
- Cary Lineker Simbolon, Nilamsari Kusumastuti, Beni Irawan. (2013). *Clustering Lulusan Mahasiswa Matematika FMIPA Untan Pontianak Menggunakan Algoritma Fuzzy C-means*. *Buletin Ilmiah Mat. Stat. Dan Terapannya (Bimaster)*, 21-26.
- Nafi'iyah, N. (2015). *Algoritma Kohonen dalam Mengubah Citra Graylevel Menjadi Citra Biner*. *Jurnal Ilmiah Teknologi dan Informasi ASIA (JITIKA)*, 49-55.
- Nafi'iyah, N. (2015). Clustering Keahlian Mahasiswa dengan SOM (Studi Khusus: Teknik Informatika Unisla). *SNATIKA* (pp. 105-110). Malang: STIKI Indonesia Malang.
- Nelson Butarbutar, Agus Perdana Windarto, Dedi Hartama, Solikhun. (2016). *Komparasi Kinerja Algoritma Fuzzy C-Means dan K-Means Dalam Pengelompokan Data Siswa Berdasarkan Prestasi Nilai Akademik Siswa*. *JURASIK (Jurnal Riset Sistem Informasi & Teknik Informatika)*, 46-55.
- Tb. Ai Munandar, Wahyu Oktri Widyarto, Harsiti. (2013). *Clustering Data Nilai Mahasiswa untuk Pengelompokan Konsentrasi Jurusan Menggunakan Fuzzy Cluster Means*. *Seminar Nasional Aplikasi Teknologi Informasi (SNATI)*, (pp. 30-33). Yogyakarta.
- Titus Kristanto, Rachman Arief. (2013). *Analisa Data Mining Metode Fuzzy untuk Customer Relationship Management pada Perusahaan Tour & Travel*. *Seminar Nasional Sistem Informasi Indonesia* (pp. 528-534). Surabaya: SESINDO.