

Hidayati.docx

by

Submission date: 28-Mar-2021 12:28PM (UTC+0700)

Submission ID: 1544132587

File name: Hidayati.docx (121.53K)

Word count: 2515

Character count: 15038

Analisis *Silhouette Coefficient* pada 6 Perhitungan Jarak *K-Means Clustering*

Silhouette Coefficient Analysis in 6 Measuring Distances of K-Means Clustering

Rahmatina Hidayati¹, Anis Zubair², Aditya Hidayat Pratama³, Luthfi Indana⁴

^{1,2,3,4}Program Studi Sistem Informasi, Fakultas Teknologi Informasi,
Universitas Merdeka Malang

E-mail: ¹rahmatina.hidayati@unmer.ac.id, ²anis.zubair.2@unmer.ac.id,
³aditya.hidayat@unmer.ac.id, ⁴luthfi.indana@unmer.ac.id

Abstrak

Clustering merupakan proses pengelompokan sekumpulan data ke dalam kluster yang memiliki kemiripan. Kemiripan dalam satu kluster ditentukan dengan perhitungan jarak. Untuk melihat performa beberapa perhitungan jarak, dalam penelitian ini penulis menguji pada 6 data yang memiliki atribut berbeda, yakni 2, 3, 4, dan 6 atribut. Dari hasil uji perbandingan rumus jarak pada *K-Means clustering* menggunakan *Silhouette coefficient* dapat disimpulkan bahwa: 1) *Chebyshev distance* memiliki performa yang stabil baik untuk data dengan sedikit atribut maupun banyak. 2) *Average distance* memiliki hasil *Silhouette coefficient* paling tinggi dibandingkan dengan pengukuran jarak lain untuk data yang memiliki *outliers* seperti data 3. 3) *Mean Character Difference* mendapatkan hasil yang baik hanya untuk data dengan sedikit atribut. 4) *Euclidean distance*, *Manhattan distance*, dan *Minkowski distance* menghasilkan nilai baik untuk data yang memiliki sedikit atribut, sedangkan untuk data yang banyak atribut mendapatkan nilai cukup yang mendekati 0,5.

Kata kunci: *K-Means, Clustering, Silhouette Coefficient*

Abstract

Clustering is the process of grouping a set of data into clusters that have similarities. The similarity in a cluster is determined by calculating the distance. To see the performance of some distance calculations, in this study the authors tested 6 data which had different attributes, namely 2, 3, 4, and 6 attributes. From the results of the comparison test for the distance formula on K-Means clustering using the Silhouette coefficient, it can be concluded that: 1) Chebyshev distance has stable performance both for data with few and many attributes. 2) Average distance has the highest Silhouette coefficient result compared to other distance measurements for data that has outliers such as data 3. 3) Mean Character Difference gets good results only for data with few attributes. 4) Euclidean distance, Manhattan distance, and Minkowski distance produce good values for data that have few attributes, while data with many attributes get a sufficient value that is close to 0.5.

Keywords: *K-Means, Clustering, Silhouette Coefficient*

1. PENDAHULUAN

Clustering merupakan proses pengelompokan sekumpulan data ke dalam kluster yang memiliki kemiripan, di mana kesamaan dalam satu kelas dimaksimalkan, sedangkan kesamaan di luar kluster diminimalkan dengan perhitungan jarak. Salah satu metode yang digunakan untuk menemukan kluster dalam data adalah *K-Means clustering* yang mana k mempresentasikan jumlah kluster [1].

Penelitian [2] membandingkan *Euclidean distance*, *Manhattan distance*, dan *Minkowski distance* dalam pengukuran jarak *K-Means*. Berdasarkan uji homogenitas kluster dengan *silhouette coefficient*, *Minkowski distance* mendapatkan nilai tertinggi, sedangkan *Euclidean distance* memperoleh akurasi terbaik dengan *Chi-square*. [3] menguji *Euclidean distance*, *Manhattan distance*, dan *Chebyshev distance* dalam pengelompokan member di salah satu tempat fitness menggunakan algoritma *K-Means*. Hasilnya, *Chebyshev distance* memiliki nilai *Silhouette coefficient* yang lebih baik dibandingkan *Euclidean distance* dan *Manhattan distance*.

Dua penelitian sebelumnya melakukan analisis perbandingan *Euclidean distance*, *Manhattan distance*, *Chebyshev distance*, dan *Minkowski distance* pada *K-Means clustering*. Selain yang sudah disebutkan, masih ada beberapa perhitungan jarak yang bisa diterapkan, di antaranya *Average distance* dan *Mean Character Difference* yang juga akan digunakan dalam penelitian ini. Masing-masing perhitungan jarak tersebut akan diaplikasikan pada 6 data yang memiliki atribut berbeda, yakni 2, 3, 4, dan 6 atribut. Hasil pengelompokan data dari keenam perhitungan jarak kemudian diuji menggunakan persamaan *Silhouette coefficient*.

2. METODE PENELITIAN

2.1 Pengumpulan data

Dalam penelitian ini data yang digunakan terdiri dari 6 data yang memiliki jumlah atribut berbeda. Data tersebut diperoleh dari Badan Pusat Statistik Indonesia, Badan Pusat Statistik Jawa Timur, dan situs resmi Provinsi Jawa Timur. Rincian dari data tersebut ditampilkan pada Tabel 1.

Tabel 1 Rincian Data Penelitian

No.	Data	Atribut	Sumber
1.	Presentase Rumah Tangga Mengakses Internet dalam 3 Bulan Terakhir	Tahun 2018-2019	hlm 449 [4]
2.	Produksi Tanaman Sayuran Semusim Menurut Jenis Tanaman (ton)	Tahun 2018-2019	hlm 281 [4]
3.	Angka Partisipasi Sekolah (APS) menurut Kota/Kab. Dan Kelompok Usia Sekolah Tahun 2019	Usia 7-12 Tahun, usia 13-15 tahun, usia 16-18 tahun	hlm 39 [5]
4.	Resiko Penularan Covid-19 di Provinsi Jawa Timur	Pasien positif yang masih aktif, pasien meninggal, dan suspek, <i>probable</i>	[6]
5.	Jumlah Des/Kel yang Memiliki Fasilitas Sekolah Menurut Provinsi dan Tingkat Pendidik Tahun 2019	SD, SMP, SMA, SMK	hlm 198-199 [4]
6.	Jumlah Des/Kel yang Memiliki Sarana Kesehatan Menurut Provinsi Tahun 2019	Rumah Sakit, Rumah Sakit Bersalin, Poliklinik, Puskesmas, Puskesmas Pembantu, Apotek	hlm 200-201 [4]

2.2 Metode

A. *K-Means Clustering*

Clustering merupakan proses pengelompokan sekumpulan data ke dalam kluster yang memiliki kemiripan. Salah satu metode yang digunakan untuk menemukan kluster dalam data adalah *K-Means clustering* yang mana k mempresentasikan jumlah kluster [1]. Suatu data dikelompokkan ke dalam satu kluster berdasarkan kemiripan atribut yang dimiliki. Kemiripan

ini bisa diketahui dengan menerapkan pengukuran jarak. Metode perhitungan jarak dalam penelitian ini antara lain [7]:

1) *Euclidean Distance*

Euclidean distance merupakan perhitungan jarak yang paling umum digunakan. Untuk 2 titik data x dan y dalam d -dimensi data, perhitungan jarak menggunakan *Euclidean distance* dirumuskan dengan Persamaan (1):

$$d_{euc}(x, y) = \sqrt{\sum_{j=1}^d (x_j - y_j)^2} \quad (1)$$

di mana,

x_j, y_j = nilai dari j atribut

2) *Manhattan Distance*

Manhattan distance yang disebut juga *city block distance* didefinisikan sebagai jumlah jarak dari semua atribut.

$$d_{man}(x, y) = \sum_{j=1}^d |x_j - y_j| \quad (2)$$

3) *Chebyshev Distance*

Chebyshev disebut juga *Maximum distance* karena dalam penerapannya mencari nilai maksimum dari selisih jarak titik data x dan y di dimensi ruang d . Jarak maksimum tersebut ditulis seperti Persamaan (3):

$$d_{che}(x, y) = \max_{1 \leq k \leq d} |x_k - y_k| \quad (3)$$

4) *Minkowski Distance*

Euclidean distance, *Manhattan distance*, dan *Chebyshev distance* merupakan tiga kasus khusus dari *Minkowski distance* yang didefinisikan seperti Persamaan (4):

$$d_{minw}(x, y) = \left(\sum_{j=1}^d |x_j - y_j|^r \right)^{\frac{1}{r}}, r \geq 1 \quad (4)$$

Jika nilai $r = 2, 1$, dan maka akan didapat *Euclidean distance*, *Manhattan distance*, dan *Chebyshev distance*. Dalam penelitian ini, menggunakan nilai $r = 1,5$.

5) *Average Distance*

Average distance merupakan modifikasi dari *Euclidean distance* untuk memperbaiki keurangan, di mana dua titik data yang tidak mempunyai nilai atribut biasanya memiliki jarak lebih kecil dibandingkan pasangan titik data yang berisi nilai atribut serupa.

$$d_{Ave}(x, y) = \frac{1}{d} \sqrt{\sum_{j=1}^d (x_j - y_j)^2} \quad (5)$$

6) *Mean Character Difference*

Mean character difference merupakan rata-rata dari *Manhattan distance*.

$$d_{mean}(x, y) = \frac{1}{d} \sum_{j=1}^d |x_j - y_j| \quad (6)$$

B. *Silhouette Coefficient*

Untuk melihat kualitas hasil pengelompokan masing-masing perhitungan jarak, maka perlu dilakukan uji homogenitas. Pengujian dilakukan setelah mencapai konvergensi 0 di mana hasil pengelompokan terakhir sama dengan pengelompokan sebelumnya. Dengan kata lain, tidak ada data yang berpindah klaster. Pengujian dihitung menggunakan persamaan *Silhouette*

coefficient. Langkah dalam menghitung *Silhouette coefficient* di mulai dengan mencari jarak rata-rata data ke- i dengan semua data di kluster yang sama, di sini kita asumsikan data ke- i berada di kluster A. Rumus dari $a(i)$ ditulis dalam Persamaan (7) [8].

$$a(i) := \frac{1}{|A|-1} \sum_{j \in A, j \neq i} d(i, j) \quad (7)$$

di mana,

A = banyaknya data di kluster A

Selanjutnya menghitung nilai $b(i)$ yang merupakan nilai minimum dari jarak rata-rata data ke- i dengan semua data di kluster berbeda. Sekarang, mari asumsikan kluster berbeda selain A dengan kluster C. Maka, perhitungan jarak rata-rata data ke- i dengan semua data di kluster C ditulis sebagai berikut:

$$d(i, C) := \frac{1}{|C|} \sum_{j \in C} d(i, j) \quad (8)$$

di mana C = banyaknya data di kluster C

Setelah menghitung $d(i, C)$ untuk semua kluster $C \neq A$, selanjutnya memilih nilai jarak paling minimum sebagai nilai $b(i)$.

$$b(i) := \min_{C \neq A} d(i, C) \quad (9)$$

Jika kluster B memiliki nilai jarak minimum, maka $d(i, B) = b(i)$ yang disebut sebagai tetangga dari data ke- i dan merupakan kluster terbaik kedua untuk data ke- i setelah kluster A. Setelah $a(i)$ dan $b(i)$ diketahui, maka proses terakhir menghitung *Silhouette coefficient* [8].

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i) - b(i)\}} \quad (10)$$

Nilai $s(i)$ berada antara -1 dan 1, di mana setiap nilai diinterpretasi sebagai berikut:

$s(i) \approx 1 \Rightarrow$ data ke- i digolongkan dengan baik (dalam A)

$s(i) \approx 0 \Rightarrow$ data ke- i berada di tengah antara dua kluster (A dan B)

$s(i) \approx -1 \Rightarrow$ data ke- i digolongkan dengan lemah (dekat ke kluster B daripada A)

Penafsiran nilai *Silhouette coefficient* ditunjukkan dalam Tabel 2 [8].

Tabel 2 Interpretasi Nilai *Silhouette Coefficient*

<i>Silhouette Coefficient</i>	Interpretasi
0.71 - 1.00	Struktur yang dihaikan kuat
0.51 - 0.70	Struktur yang dihasilkan baik
0.26 - 0.50	Struktur yang dihasilkan lemah
≤ 0.25	Tidak tersruktur

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan 6 data dengan jumlah atribut berbeda yakni 2, 3, 4, dan 6 atribut. Salah satu data yang memiliki 4 atribut adalah data jumlah desa/kelurahan yang memiliki fasilitas sekolah menurut provinsi dan tingkat pendidikan tahun 2019 yang ditampilkan pada Tabel 3.

Tabel 3 Jumlah Des/Kel yang Memiliki Fasilitas Sekolah

No.	Provinsi	SD	SMP	SMA	SMK
1	Aceh	3475	1405	716	190
2	Sumatera Utara	5039	2280	1094	678
3	Sumatera Barat	1243	793	410	173
4	Riau	1816	1187	588	254
5	Jambi	1471	770	359	157
6	Sumatera Selata	2985	1333	639	233
7	Bengkulu	1187	477	186	100
8	Lampung	2532	1429	654	397
9	Kepulauan Bang	388	206	80	49
10	Kepulauan Riau	396	244	121	65
11	DKI Jakarta	264	257	215	211
12	Jawa Barat	5948	4187	2022	1989
13	Jawa Tengah	8443	3607	1266	1212
14	DI Yogyakarta	437	316	144	147
15	Jawa Timur	8443	4762	2420	1586
16	Banten	1541	1235	689	519
17	Bali	709	321	144	124
18	Nusa Tenggara B	1129	875	548	269
19	Nusa Tenggara T	3202	1613	575	280
20	Kalimantan Bara	2052	1117	403	171
21	Kalimantan Teng	1553	792	277	117
22	Kalimantan Selat	1867	769	305	104
23	Kalimantan Timu	984	541	234	153
24	Kalimantan Utar	316	154	59	30
25	Sulawesi Utara	1556	725	239	172
26	Sulawesi Tengah	1925	945	336	168
27	Sulawesi Selatan	2947	1739	770	337
28	Sulawesi Tengga	1871	887	386	156
29	Gorontalo	655	361	107	52
30	Sulawesi Barat	630	404	156	111
31	Maluku	1089	597	259	97
32	Maluku Utara	1093	629	292	140
33	Papua Barat	928	290	126	48
34	Papua	2147	612	236	126

Langkah-langkah K-Means Clustering:

- (1) Tentukan jumlah k
 Pada penelitian ini, k untuk seluruh data ditetapkan sama dengan 3.
- (2) Tentukan nilai *centroid* awal
 Nilai *centroid* didapat berdasarkan distribusi data. Tabel 4 menampilkan *centroid* awal dari data fasilitas sekolah di mana klaster 1 = nilai maksimu, klaster 2 = nilai rata-rata, dan klaster 3 = nilai minimum.

Tabel 4 Nilai *Centroid* Awal

	SD	SMP	SMA	SMK
c1	8443	4762	2420	1989
c2	2125,324	1113,5	501,6176	312,2059
c3	264	154	59	30

Perhitungan jarak titik data ke-1 dengan *centroid* kluster 1 menggunakan Persamaan (1) sampai Persamaan (6) dinyatakan sebagai berikut:

$$d_{euc}(x, y) = \sqrt{(3475 - 8443)^2 + (1405 - 4762)^2 + (716 - 2420)^2 + (190 - 1989)^2}$$

$$= 6487,72$$

$$d_{man}(x, y) = |3475 - 8443| + |1405 - 4762| + |716 - 2420| + |190 - 1989|$$

$$= 11828$$

$$d_{che}(x, y) = \max|3475 - 8443| + \max|1405 - 4762| + \max|716 - 2420| + \max|190 - 1989|$$

$$= 4968$$

$$d_{minw}(x, y) = (|3475 - 8443|^{1,5} + |1405 - 4762|^{1,5} + |716 - 2420|^{1,5} + |190 - 1989|^{1,5})^{1/1,5}$$

$$= 7818,369$$

$$d_{Ave}(x, y) = \frac{1}{34} \sqrt{(3475 - 8443)^2 + (1405 - 4762)^2 + (716 - 2420)^2 + (190 - 1989)^2}$$

$$= 1052,447$$

$$d_{mean}(x, y) = \frac{1}{34} (|3475 - 8443| + |1405 - 4762| + |716 - 2420| + |190 - 1989|)$$

$$= 311,263$$

Lakukan perhitungan jarak titik data ke-1 dengan nilai *centroid* kluster 2 dan juga kluster 3. Serta lakukan perhitungan serupa untuk titik data ke-2 sampai titik data ke-34. Setelah mengetahui jarak data dengan *centroid* semua kluster, selanjutnya mengelompokkan data ke dalam kluster yang memiliki hasil jarak minimum.

(3) *Update* nilai *centroid*

Nilai *centroid* baru merupakan rata-rata nilai data yang berada di tiap kluster. Pada hasil perhitungan *Euclidean distance*, Provinsi Jawa Barat, Jawa Tengah, dan Timur berada dalam kluster 1. Jadi, perhitungan *centroid* baru kluster 1 dilakukan dengan rumus berikut:

$$c1_{SD} = \frac{1}{3} (5948 + 8443 + 8443) = 7611,333$$

$$c1_{SMP} = \frac{1}{3} (4178 + 3607 + 4762) = 4185,333$$

$$c1_{SMA} = \frac{1}{3} (2022 + 1266 + 2420) = 1902,667$$

$$c1_{SMK} = \frac{1}{3} (1989 + 1212 + 1586) = 1595,667$$

Lakukan perhitungan yang sama untuk *centroid* kedua pada kluster 2 dan 3. Setelah mendapatkan nilai *centroid* baru, selanjutnya menghitung jarak kembali. Proses ini dilakukan berulang sampai mencapai konvergensi 0. Tabel 5 menampilkan jumlah data masing-masing kluster pada pengelompokan terakhir.

Tabel 5 Jumlah data Masing-Masing Kluster

<i>Measure Distance</i>	C1	C2	C3
<i>Euclidean</i>	3	13	18
<i>Manhattan</i>	3	9	22
<i>Chebyshev</i>	4	14	16
<i>Minkowski</i>	3	12	19
<i>Average</i>	3	13	18
<i>Mean Character Difference</i>	3	20	11

(4) Uji Homogenitas

Untuk melihat kemiripan data yang tergabung ke dalam satu kelompok, maka perlu dilakukan uji homogenitas. Pengujian ini menggunakan rumus *Silhouette coefficient*. Hasil perhitungan nilai $a(i)$, $b(i)$, dan *Silhouette coefficient* (s) masing-masing data ditunjukkan di Tabel 6.

Tabel 6 Nilai $a(i)$, $b(i)$, dan $s(i)$ *Euclidean Distance*

a(1)	1358,78	b(1)	2792,73	s(1)	0,5135
a(2)	2991,21	b(2)	3619,69	s(2)	0,1736
a(3)	644,96	b(3)	1472,11	s(3)	0,5619
a(4)	1048,72	b(4)	1240,08	s(4)	0,1543
a(5)	744,19	b(5)	1291,30	s(5)	0,4237
a(6)	1056,24	b(6)	2305,37	s(6)	0,5418
a(7)	544,66	b(7)	1688,09	s(7)	0,6774
a(8)	977,17	b(8)	1967,49	s(8)	0,5033
a(9)	672,95	b(9)	2507,73	s(9)	0,7317
a(10)	646,81	b(10)	2475,57	s(10)	0,7387
a(11)	755,59	b(11)	2565,05	s(11)	0,7054
a(12)	2701,90	b(12)	5025,14	s(12)	0,4623
a(13)	2228,24	b(13)	6433,75	s(13)	0,6537

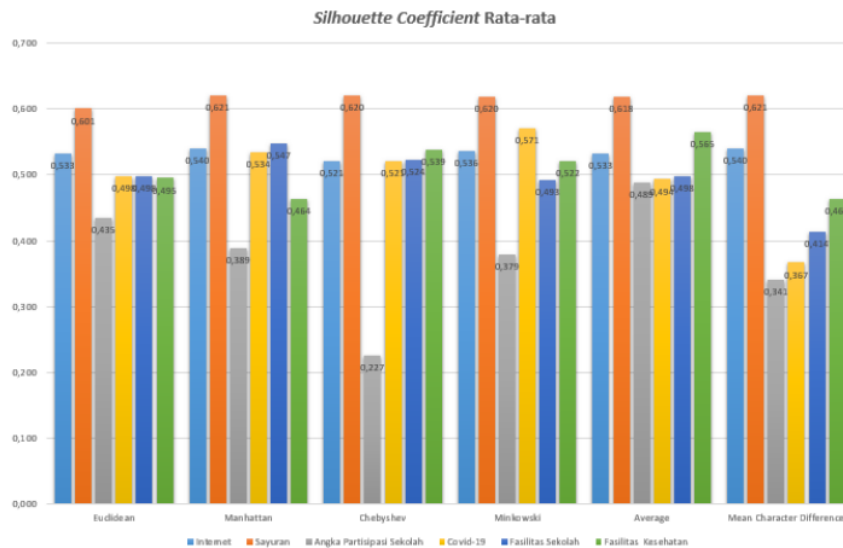
a(14)	607,77	b(14)	2400,40	s(14)	0,7468
a(15)	2148,65	b(15)	7206,02	s(15)	0,7018
a(16)	1306,97	b(16)	1202,43	s(16)	-0,0800
a(17)	505,86	b(17)	2163,15	s(17)	0,7661
a(18)	728,33	b(18)	1548,70	s(18)	0,5297
a(19)	1201,54	b(19)	2604,78	s(19)	0,5387
a(20)	947,40	b(20)	1344,39	s(20)	0,2953
a(21)	803,63	b(21)	1237,18	s(21)	0,3504
a(22)	1112,22	b(22)	1039,55	s(22)	-0,0653
a(23)	482,66	b(23)	1814,32	s(23)	0,7340
a(24)	752,71	b(24)	2598,28	s(24)	0,7103
a(25)	788,54	b(25)	1265,78	s(25)	0,3770
a(26)	1004,24	b(26)	1150,35	s(26)	0,1270
a(27)	1164,48	b(27)	2483,86	s(27)	0,5312
a(28)	1035,48	b(28)	1085,64	s(28)	0,0462
a(29)	518,08	b(29)	2205,90	s(29)	0,7651
a(30)	512,05	b(30)	2195,17	s(30)	0,7667
a(31)	504,41	b(31)	1701,83	s(31)	0,7036
a(32)	513,66	b(32)	1676,45	s(32)	0,6936
a(33)	529,04	b(33)	2007,31	s(33)	0,7364
a(34)	1153,74	b(34)	1287,85	s(34)	0,1041

$$S_{rata-rata} = \frac{1}{34}(16,9203) = 0,4976$$

Tabel 7 menampilkan hasil keseluruhan *Silhouette coefficient* rata-rata semua data pada masing-masing jarak, sedangkan Gambar 1 menunjukkan grafik perbandingannya.

Tabel 7 Hasil *Silhouette Coefficient* Rata-rata

Data \ Jarak	Euclidean	Manhattan	Chebyshev	Minkowski	Average	Mean Character Difference
Internet	0,533	0,540	0,521	0,536	0,533	0,540
Sayuran	0,601	0,621	0,620	0,620	0,618	0,621
Angka Partisipasi Sekolah	0,435	0,389	0,227	0,379	0,489	0,341
Covid-19	0,498	0,534	0,521	0,571	0,494	0,367
Fasilitas Sekolah	0,498	0,547	0,524	0,493	0,498	0,414
Fasilitas Kesehatan	0,495	0,464	0,539	0,522	0,565	0,464



Gambar 1 Grafik perbandingan

4. KESIMPULAN DAN SARAN

Dari hasil uji perbandingan rumus jarak pada *K-Means clustering* menggunakan *Silhouette coefficient*, dapat disimpulkan bahwa:

- 1) *Chebyshev distance* memiliki performa yang stabil baik untuk data dengan sedikit atribut maupun banyak.
- 2) *Average distance* memiliki hasil *Silhouette coefficient* paling tinggi dibandingkan dengan pengukuran jarak lain untuk data yang memiliki *outliers* seperti data 3.
- 3) *Mean Character Difference* mendapatkan hasil yang baik hanya untuk data dengan sedikit atribut.
- 4) *Euclidean distance*, *Manhattan distance*, dan *Minkowski distance* menghasilkan nilai baik untuk data yang memiliki sedikit atribut, sedangkan untuk data yang banyak atribut mendapatkan nilai cukup yang mendekati 0,5.

Untuk penelitian selanjutnya bisa membandingkan rumus jarak yang lain dengan varian data yang lebih banyak.

DAFTAR PUSTAKA

- [1] Han, J., Kamber, M., 2006, *Data Mining: Concepts and Techniques 2nd Edition*, Elsevier
- [2] Nishom, M., 2019, Perbandingan Akurasi Euclidean Distance, Minkowski Distance, dan Manhattan Distance pada Algoritma *K-Means Clustering* berbasis Chi-Square, *Jurnal Informatika: Jurnal Pengembangan IT (JPIT)*, Vol.04, No.01, hal 20-24.

- [3] Anggara, M., Sujiani, H. dan Nasution, H., 2016, Pemilihan Distance Measure Pada *K-Means Clustering* Untuk Pengelompokkan *Member* Di Alvaro Fitness, *Jurnal Sistem dan Teknologi Informasi (JUSTIN)*, Vol. 1, No. 1, hal 1-6.
- [4] Statistik Indonesia, 2020, BPS-Statistics Indonesi, ISSN: 0126-2912
- [5] Statistik Pendidikan Provinsi Jawa Timur, 2019, BPS Provinsi Jawa Timur.
- [6] <http://covid19.go.id> diakses Februari 2021
- [7] Gan, G., Ma, C., and Wu, J., 2007, *Data Clustering: Theory, Algorithms, and Applications*, ASA-SIAM Series on Statistics and Applied Probability. Society for Industrial and Applied Mathematics, Alexandria, VA.
- [8] Struyf, A., Hubert, M., and Rousseeuw, P. J., 1997, Clustering in an Object-Oriented Environment, *Journal of Statistical Software*, Vol 1, Issue 4, 1-30.

Hidayati.docx

ORIGINALITY REPORT

8%

SIMILARITY INDEX

8%

INTERNET SOURCES

1%

PUBLICATIONS

3%

STUDENT PAPERS

PRIMARY SOURCES

1	Submitted to Universitas Dian Nuswantoro Student Paper	3%
2	ejournal.poltektegal.ac.id Internet Source	1%
3	repository.ub.ac.id Internet Source	1%
4	ejournal.akakom.ac.id Internet Source	1%
5	repository.unpas.ac.id Internet Source	1%
6	www.ejurnal.stmik-budidarma.ac.id Internet Source	1%
7	123dok.com Internet Source	1%

Exclude quotes On

Exclude matches < 1%

Exclude bibliography On