

# PENERAPAN ALGORITMA K-MEANS CLUSTERING PADA K-HARMONIC MEANS UNTUK SCHEDULE PREVENTIVE MAINTENANCE SERVICE

Muryan Awaludin

Universitas Dirgantara Marsekal Suryadarma

Email: muryanawaludin1@gmail.com

**Abstract:** Vehicle maintenance is a very important sector in terms of economy and safety, a good understanding of vehicle maintenance is very important from the owner of the vehicle itself or from the company. Maintenance for the vehicle is considered as part structure of the activity in a series of improvements, as well as a planned activity to prevent potential errors resulting in damage. Schedule preventive maintenance is one of the methods that are used for vehicle maintenance scheduling. SPM is widely used because it can determine component reliability item, so as to reduce the cost of repairs, but this method has the disadvantage that reparations are made to the unit item could potentially breakdown, as well as the application of SPM only on certain types of vehicles. To solve this problem it is proposed the one application of a method, algorithm K-Means Clustering is one of the methods to be applied in the schedule vehicle maintenance services, K-Means algorithm is widely used because it is easy and simple. From the models created will then be tested using Confusion Matrix to determine how the level of accuracy, and describes the results of a positive predictive accuracy results are correct, the positive predictions were wrong, negative predictions are true, and false negative predictions. From these experiments showed that the application of K-Means Clustering algorithms in the vehicle's maintenance schedule capable of generating predictive value and accuracy that is optimal by 70%.

**Keywords:** Vehicle Maintenance, K-Means Clustering, Confusion Matrix

## 1 PENDAHULUAN

Pada tahun 2014, ada lebih dari seratus juta kendaraan bermotor di Indonesia (Bermotor, 2014). Untuk alasan ini, perawatan kendaraan merupakan sektor yang sangat penting dari segi ekonomi dan keselamatan (Rubio-romero, Suárez-cebador, & Pardo-ferreira, 2015), pemahaman yang baik tentang perawatan kendaraan sangatlah penting dilakukan untuk mengurangi keluhan, biaya yang keluar dari perusahaan, maupun dari pemilik kendaraan itu sendiri, serta bentuk dalam menjaga lingkungan. Meskipun demikian, sangatlah sedikit perhatian oleh pemilik kendaraan dalam hal perawatan kendaraan. Kegiatan perawatan kendaraan dianggap sebagai bagian dari struktur kegiatan dalam rangkaian perbaikan (Hedvall, Dubois, & Lind,

2016), baik dalam perawatan ringan, sedang, maupun pada tingkatan perawatan yang terbilang berat.

Penjadwalan perawatan kendaraan secara berkala merupakan salah satu cara tepat untuk mengatasi masalah tersebut, tujuannya adalah untuk memelihara kemampuan sistem dan mengendalikan biaya sehingga sistem harus dirancang serta dipelihara untuk mencapai standar mutu dan kinerja yang diharapkan. Perawatan kendaraan merupakan suatu kegiatan yang terencana untuk mencegah terjadinya kesalahan potensial yang mengakibatkan kerusakan. Perhatikan bahwa biaya pemeliharaan mencakup persentase besar dari total biaya operasional, sehingga sangat wajar untuk memasukkan kegiatan pemeliharaan dalam jadwal (Yoo & Lee, 2016;

Gustavsson, Patriksson, Strömberg, Wojciechowski, & Önnheim, 2014). Dalam jadwal perawatan kendaraan yang dilakukan secara berkala pada setiap kendaraan sangatlah berbeda-beda penanganannya, dilihat dari segi merk, type/jenis kendaraan, serta jarak tempuh pada kendaraan itu sendiri.

Preventive Maintenance (PM), Corrective Maintenance (CM), (Lin, Huang, & Fang, 2015; Wang, 2002; Valdez-Flores & Feldman, 1989), dan Schedule Preventive Maintenance (SPM) (Asti & Prasetyawan, 2013) merupakan suatu metode pemeliharaan untuk dapat menentukan penjadwalan kendaraan secara tepat dan akurat. Preventive maintenance (PM) adalah pemeliharaan yang terjadi ketika sebuah system masih beroperasi. Menurut MIL-STD-721B, PM dapat diartikan suatu tindakan yang dilakukan dalam upaya untuk mempertahankan item dalam kondisi tertentu dengan menyediakan pemeriksaan sistematis, deteksi, dan pencegahan kegagalan yang akan baru terjadi. Corrective maintenance (CM) adalah pemeliharaan yang terjadi ketika sistem gagal disebut juga dengan breakdown atau run to failure maintenance. Menurut MIL-STD- 721B, CM sebagai perbaikan atau tindakan yang dilakukan akibat dari kegagalan, untuk mengembalikan item ke kondisi yang ditentukan. Schedule preventive maintenance (SPM) adalah suatu tindakan pemeliharaan yang dilakukan secara terjadwal dalam upaya reliable item yang diganti atau masih bisa digunakan (belum mencapai batas masa hidupnya).

PM memiliki kelebihan penggantian unit selalu diganti di  $T$  umurnya atau pada kegagalan, mana yang terlebih dahulu, di mana  $T$  adalah konstan (Barlow & Hunter,

1960), setiap penggantian item dapat diperhitungkan, kerusakan dapat dibatasi, perawatan dilakukan secara berkala, dapat memprediksi jumlah perbaikan dan petunjuk waktu, mengurangi konsep perbaikan dan pemeliharaan yang tidak sempurna (Pham & Wang, 1996), akan tetapi PM memiliki kelemahan biaya pemeliharaan terus menerus saat fungsi dari usia unit atau banyaknya perbaikan (Pham & Wang, 1996; Valdez-Flores & Feldman, 1989).

CM memiliki kelebihan dapat mempelajari kualitas dari item unit, waktu usia unit dapat diketahui, dapat menganalisa sebab-sebab dari kegagalan serta cara-cara mengatasinya, perlunya perbaikan saat kondisi system breakdown atau gagal, sehingga biaya untuk perbaikan dikeluarkan pada waktu yang cukup lama.

SPM dapat memecahkan permasalahan PM dan CM tersebut, yaitu pada faktor biaya yang dikeluarkan untuk perawatan atau perbaikan, perlu cepatnya menemukan material dan personil untuk reparasi, serta tidak adanya penjadwalan dalam perbaikan/pemeliharaan (Asti & Prasetyawan, 2013), yang mana ini tepat untuk melakukan penjadwalan pemeliharaan kendaraan secara berkala pada penelitian ini. Akan tetapi SPM memiliki kelemahan pada reparasi yang dilakukan terhadap item unit bisa berpotensi breakdown, sehingga kurang efisien dalam perawatan, serta penerapan SPM hanya pada kendaraan jenis tertentu (Asti & Prasetyawan, 2013; Zachary, 2014; Chang, 2014).

K-Means merupakan algoritma clustering yang paling populer digunakan karena memiliki kelebihan yaitu algoritmanya sederhana, mudah di implementasikan, dan merupakan salah satu metode yang cukup efisien dalam hal

kompleksitas nya  $O(nkt)$  (Aggarwal, Aggarwal, & Gupta, 2012). Dengan adanya penerapan metode K-Means pada penentuan jadwal perawatan kendaraan secara berkala mampu mengatasi masalah pada PM, CM, dan SPM.

## 2 PENELITIAN TERKAIT

Model penelitian Zhao, Al-Khalifa, Magid, & Nakagawa (2017), sebuah penelitian tentang age replacement dengan skema klasifikasi model penggantian dan perhitungan usia komponen yang dapat digunakan untuk pemeliharaan (Zhao, Al-khalifa, Magid, & Nakagawa, 2017), klasifikasi ini dimaksud untuk membantu serta sebagai pedoman untuk mengklasifikasikan model pemeliharaan sehingga pembuat keputusan dapat mengenali model yang paling sesuai dengan masalah pemeliharaan-Nya. **Random Replacement, Replacement at time T and number N**, dan **Replacement over time T** (Chen, Mizutani, & Nakagawa, 2010) merupakan tiga jenis model pemeliharaan Age Replacement (AR) yang sering digunakan dalam pemeliharaan. Metode ini sangat populer digunakan sejak pertama kali diperkenalkan oleh (Barlow & Hunter, 1960).

Awalnya, kendaraan direview terlebih dahulu history servicenya, dari hasil review history tersebut, akan menyajikan data-data problem, penanganannya, serta data penggantian item komponen/spareparts. Berdasarkan data kerusakan kendaraan tersebut, dapat diketahui waktu antara tiap-tiap kerusakan yang di urutkan dari yang terkecil sampai dengan yang bernilai besar (Purnama, Putra, & Kalamollah, 2015). Setiap pengganti item komponen spareparts pada  $T$  usia menjadikan titik ukur dimana  $T$  adalah konstan  $t_0 = 0$  (Barlow & Hunter, 1960). Kemudian, sebagai konsep perbaikan yang paling sedikit dari pemeliharaan yang

tidak sempurna sehingga dibutuhkan pemeliharaan berkala/periodic PM  $t_0 = T$  (Pham & Wang, 1996). Selanjutnya menentukan model klasifikasi perbaikan, fungsi padat probabilitas dan dilanjutkan dengan menentukan keandalan komponen, dengan demikian dapat diketahui perbaikan yang optimal.

Model penelitian Rasindyo, Kusmaningrum, & Helianty (2015), Pada penelitian yang dilakukan oleh (Rasindyo, Kusmaningrum, & Helianty, 2015) memperkenalkan model pemeliharaan reliability centered maintenance (RCM) dimana model pemeliharaan ini dilakukan untuk menjamin suatu asset fisik dapat berlangsung terus memenuhi dengan fungsi yang diharapkan dalam konteks suatu pendekatan pemeliharaan yang mengkombinasikan praktek dan strategi dari preventive maintenance (PM) dan corrective maintenance (CM). Dimana implementasi RCM dapat berlangsung secara efektif dengan menganalisis 7 pertanyaan diantaranya **System Function (SF)**, **Functional Failure (FF)**, **Failure Mode (FM)**, **Failure Effect (FE)**, **Failure Consequence (FC)**, **Proactive Task and Task Interval (PTTI)**, dan **Default Action (DA)**, ketujuh pertanyaan dituangkan dalam bentuk Failure Mode dan Effect Analysis (FMEA) dan RCM II Decision Diagram yang tergabung dalam RCM Worksheet (Nowlan, 1978).

Pengumpulan data kegagalan merupakan proses awal untuk penerapan RCM, selanjutnya menentukan batasan terhadap system, batasan system disini diperlukan untuk mengetahui input dan output dari system sehingga menghasilkan informasi mengenai in/out interface. Dari batasan system tersebut kemudian menentukan functional block diagram untuk mengidentifikasi system dengan

terperinci, fungsi system disini untuk mengetahui informasi mengenai jenis kegagalan dan kerusakan yang terjadi pada system, kemudian menentukan Failure Mode and Effect Analysis (FMEA) pada proses ini mode kegagalan dapat mencakup semua kegagalan yang mungkin terjadi serta menganalisisnya. Logic Tree Analysis (LTA) disini untuk menekan suatu prioritas dan sumber daya pada setiap mode kegagalan untuk mengklasifikasikan model kegagalan karena tidaklah sama, selanjutnya proses Task Selection (TS) dilakukan untuk menentukan kebijakan yang paling mungkin serta efektif untuk setiap mode kegagalan (Syahrudin, 2013). Sehingga dari proses tersebut membuahkan hasil akhir berupa analisis task untuk menentukan analisis perbandingan kebijakan perawatan yang optimal.

Model penelitian Asti & Prasetyawan (2013), Sebuah penelitian yang dilakukan oleh (Asti & Prasetyawan, 2013), melakukan sebuah pengembangan age replacement (AR) & reliability centered maintenance (RCM) dengan menggunakan schedule preventive maintenance (SPM), dimana untuk membuat jadwal maintenance kendaraan terlebih dahulu mengidentifikasi susunan komponen mobil (block diagram). Susunan komponen digunakan untuk melihat hubungan seri-paralel antara komponen pembangun produk yang terdiri dari mesin, chassis & body, sehingga dapat dilihat secara detail reliability item tiap-tiap komponen.

Pada perhitungan reliability ini diperlukan input parameter kerusakan komponen (*etha* & *beta*) yang diperoleh dari hasil fitting distribusi menggunakan software weibull++6. Setelah diketahui nilai reliability dari setiap komponen, maka dapat diketahui pada periode berapa suatu komponen harus diganti. Selanjutnya

dikembangkan algoritma jadwal penggantian komponen, sehingga berdasarkan algoritma jadwal penggantian maka dibuatlah jadwal penggantian untuk tiap komponen dan penentuan waktu pemeliharannya.

### 3 METODE YANG DIUSULKAN

Kami mengusulkan sebuah metode yang disebut 2K-Means, metode ini akan digambarkan secara skematik dan disertai dengan formula perhitungan. Penulis melakukan penelitian di PT XYZ, merupakan anak perusahaan dari HIDUP BARU GROUP yang bergerak dalam bidang jasa transportasi bus pariwisata dan antar jemput karyawan. Berdiri sejak tahun 2004 silam, anak perusahaan HIDUP BARU GROUP ini bergerak pada penyewaan kendaraan (Rent A Car) khusus industry, dan sudah memiliki 4.793 unit kendaraan yang tersebar diseluruh nusantara, serta memiliki lima cabang workshop diantaranya Jakarta, Bandung, Semarang, Surabaya, & Lampung.

Data pada penelitian ini menggunakan *Dataset Eksperimen, Blok Diagram, History Service Car`s*, dan *Interval Service* yang diperoleh dari aktivitas perbaikan di PT XYZ serta yang digunakan oleh para peneliti Asti & Prasetyawan (2013) serta J. Purnama (2015).

Dataset yang digunakan oleh penulis seperti yang ditampilkan pada Tabel 3.1.

Tabel 3.1 Dataset Eksperimen

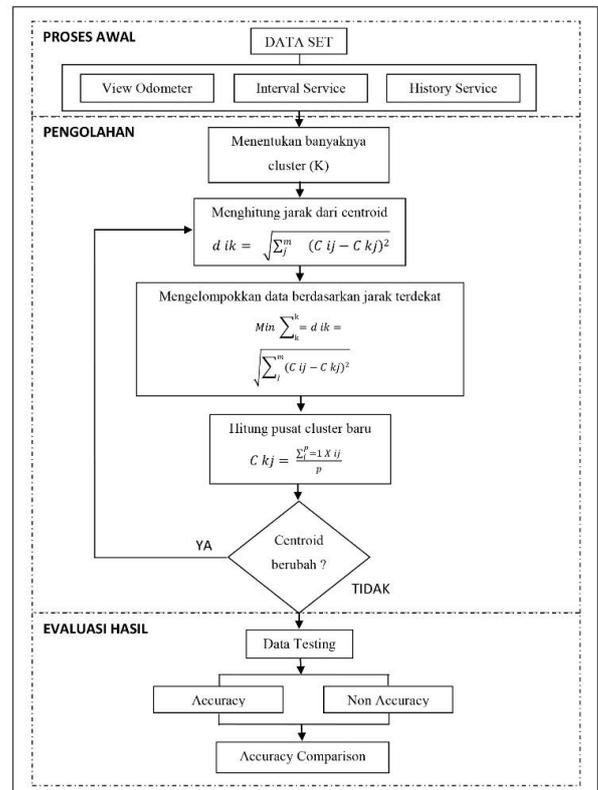
No	Item komponen	Replacem	Adjusment	Inspection	Clean Up	Lubrication	Repair
1	Accu / Battery	100	0	10	10	0	0
2	Alternator	0	30	10	0	10	150
3	Air Filter	30	0	10	10	0	0
4	Bearing Release	150	0	50	0	0	0
5	Brake Shoe	80	40	40	40	0	0
6	Brake Drum	200	50	50	50	0	0
7	Brake Pad	150	0	50	50	0	0
8	Brake Fluid	50	0	10	20	0	0
9	Ball Joint and Boot	250	0	40	0	0	0
10	Bohlam Halogent	150	0	10	0	0	0
11	Bearing Whell Front	150	0	50	0	0	0
12	Bearing Whell Rear	150	0	50	0	0	0
13	Cover Clutch	150	0	50	0	0	0
14	Clutch Fluid	50	0	10	50	0	0
15	Charcoal Canister	0	0	40	0	0	0
16	Cross Joint Kopel	180	0	50	0	20	0
17	Differential Fluid	40	0	10	0	0	0
18	Disc Clutch	150	0	50	0	0	0
19	Drive Belt	100	0	20	0	0	0
20	Filter Air Conditioner	50	0	10	10	0	0
21	Engine Oil	10	0	5	0	0	0
22	Fuel Filter Out Tank	80	0	10	10	0	0
23	Injection Nozle	0	100	20	0	0	0
24	Injection Pump	0	0	50	0	0	150
25	Master Clutch Cylinder Up	150	50	20	50	0	0
26	Master Clutch Cylinder Low	150	0	20	50	0	0
27	Master Brake Cylinder Up	150	50	20	50	0	0
28	Master Brake Cylinder Low	150	0	20	50	0	0
29	Motor Fan	150	0	50	0	0	0
30	Power Steering Fluid	50	0	20	50	0	0
31	Refrigerant AC	150	0	50	150	0	0
32	Shock Absorber Front	200	0	50	0	0	0
33	Shock Absorber Rear	200	0	50	0	0	0
34	Stater Assy	0	0	50	0	0	100
35	Radiator Coolant	80	0	20	0	0	0
36	Radiator	0	0	10	0	0	150
37	Transmission Fluid	40	0	0	0	0	0
38	Tire	120	10	10	0	0	0
39	Timing Belt	150	0	50	0	0	0
40	V-Belt	150	0	10	0	10	0

Model akan dibentuk dari data yang sudah diolah, dan hasil pengolahan model akan dibandingkan dengan model yang ada saat ini. Metode yang disulkan seperti pada Gambar 3.1

**Proses Awal**, Pada proses awal ini dataset eksperimen akan melalui beberapa

proses review untuk memastikan tiap-tiap reliability item unit/spareparts yang selanjutnya akan masuk ke tahap pengolahan dengan algoritma *K-Means Clustering* dan *K-Harmonic Means Clustering*. **Proses kedua yaitu Pengolahan**, pada tahap ini, dataset yang sudah direview pada proses awal selanjutnya akan diolah dengan penerapan algoritma *K-Means Clustering* dan *K-Harmonic Means Clustering* sehingga mendapatkan hasil yang diinginkan.

**Proses ketiga Evaluasi**, merupakan proses evaluasi, model yang terbentuk dari penerapan algoritma *K-Means Clustering* dan *K-Harmonic Means Clustering* dan selanjutnya akan dilakukan testing dan mendapatkan hasil accuracy dan non accuracy.



Gambar 3.1 Metode 2K-Means

Ekperimen dan pengujian modelnya terdapat 5 tahapan, diantaranya:

1. Menyiapkan dataset untuk eksperimen.
2. Mendesain arsitektur algoritma *K-Means Clustering* dan *K-Harmonic Means Clustering*.
3. Melakukan data testing pada algoritma *K-Means Clustering* dan *K-Harmonic Means Clustering*.
4. Evaluasi model yang dihasilkan dari data testing sehingga mendapatkan hasil accuracy dan non accuracy.
5. Mendapatkan hasil akhir penerapan algoritma *K-Means Clustering* dan *K-Harmonic Means Clustering*.

Dalam melakukan penelitian ini, diperlukan proses pengujian eksperimen terhadap model yang diusulkan dengan menggunakan *RapidMiner* dan *IBM SPSS Statistic*. Proses eksperimen dan pengujian model ini menggunakan bagian dari dataset yang ada.

**Proses keempat, evaluasi dan hasil, model** yang terbentuk akan diuji dengan menggunakan confusion matrix untuk mengetahui tingkat accuracy, Tabel 3.2 merupakan tampilan dari confusion matrix. Confusion matrix akan menggambarkan hasil accuracy mulai dari prediksi positif yang benar, prediksi positif yang salah, prediksi negative yang benar, dan prediksi negative yang salah. Accuracy akan dihitung dari seluruh prediksi yang benar (baik dari prediksi positif dan negative) dibandingkan dengan seluruh data testing. Semakin tinggi nilai accuracy, semakin baik pula model yang dihasilkan.

Tabel 3.2 Confusion Matrix

Confusion Matrix		Target		
		Positive	Negative	
Model	Positive	True (+)	False (+)	Positive Predictive Value $a/(a+b)$
	Negative	False (-)	True (-)	Negative Predictive Value $d/(c+d)$
		Sensitivity	Specificity	Accuracy = $(a+d)/(a+b+c+d)$
		$a/(a+c)$	$d/(b+d)$	

#### 4 HASIL EKSPERIMEN

Tujuan dari penelitian ini adalah untuk mengetahui komparasi tingkat *accuracy* dari penerapan algoritma *K-Means Clustering* dan *K-Harmonic Means Clustering* untuk schedule preventive maintenance pada PT XYZ.

Data hasil penelitian K-Means Clustering Data dari penelitian ini pertama-tama menentukan titik pusat awal cluster seperti yang ditunjukkan pada Tabel 4.1 dibawah ini :

Tabel 4.1 Titik Pusat Awal Cluster

No	Item komponen	Replacement	Adjustment	Inspection	Clean up	Lubrication	Repair
21	Engine oil	10	0	5	0	0	0
29	Motor Fan	150	0	50	0	0	0

Dari titik pusat awal cluster, selanjutnya akan dihitung jarak pusat cluster antara data dengan pusat awal cluster dengan menggunakan persamaan *Euclidean Distance* seperti yang ditunjukkan pada persamaan (4.1) dibawah ini:

$$d_{ik} = \sqrt{\sum_j^n (C_{ij} - C_{kj})^2}$$

(4.1)

Hasil perhitungan matrik jarak dapat dilihat pada Tabel 4.2 dibawah ini :

Tabel 4.2 Hasil Perhitungan Matrik Jarak

No	Jarak Data Ke Pusat Cluster	Cluster I	Cluster 2
1	Jarak data ke-1 pusat cluster	90.7	63.25
2	Jarak data ke-2 pusat cluster	153.05	24.5
3	Jarak data ke-3 pusat cluster	22.91	126.1
4	Jarak data ke-4 pusat cluster	147.05	0
5	Jarak data ke-5 pusat cluster	96.6	52.92
6	Jarak data ke-6 pusat cluster	207.7	86.60
7	Jarak data ke-7 pusat cluster	155.32	50
8	Jarak data ke-8 pusat cluster	45	105.83
9	Jarak data ke-9 pusat cluster	242.54	99.5
10	Jarak data ke-10 pusat cluster	140.1	40
11	Jarak data ke-11 pusat cluster	147.05	0
12	Jarak data ke-12 pusat cluster	147.05	0
13	Jarak data ke-13 pusat cluster	151.74	0
14	Jarak data ke-14 pusat cluster	64.23	95.4

15	Jarak data ke-15 pusat cluster	33.54	150.33
16	Jarak data ke-16 pusat cluster	176.98	36.05
17	Jarak data ke-17 pusat cluster	30.41	117.05
18	Jarak data ke-18 pusat cluster	140.1	0
19	Jarak data ke-19 pusat cluster	91.24	58.31
20	Jarak data ke-20 pusat cluster	41.53	107.24
21	Jarak data ke-21 pusat cluster	0	147.054412
22	Jarak data ke-22 pusat cluster	70.9	80
23	Jarak data ke-23 pusat cluster	100.62	115.8
24	Jarak data ke-24 pusat cluster	157.8	0
25	Jarak data ke-25 pusat cluster	157.6	64.03
26	Jarak data ke-26 pusat cluster	149.41	40
27	Jarak data ke-27 pusat cluster	157.6	64.03
28	Jarak data ke-28 pusat cluster	149.41	40
29	Jarak data ke-29 pusat cluster	147.05	0
30	Jarak data ke-30 pusat cluster	65.8	91.7
31	Jarak data ke-31 pusat cluster	210.1	150
32	Jarak data ke-32 pusat cluster	195.3	50
33	Jarak data ke-33 pusat cluster	195.3	50
34	Jarak data ke-34 pusat cluster	109.20	111.80

Dari hasil perhitungan matrik jarak akan dilakukan perbandingan dan dipilih jarak yang paling dekat antara data dengan pusat cluster, jarak ini akan menunjukkan bahwa data yang memiliki jarak terdekat berada dalam satu kelompok dengan pusat cluster terdekat, pengelompokkan data tersebut dapat dilihat pada Tabel 4.3 di bawah ini. Jarak terdekat untuk cluster 1 berarti data tersebut berada dalam kelompok 1, dan cluster 2 berarti data tersebut berada dalam kelompok 2.

Tabel 4.3 Pengelompokan Data

No	Data Ke	Cluster 1	Cluster 2	Jarak Terdekat
1	1	90.7	63.25	Cluster 2
2	2	153.05	24.5	Cluster 2
3	3	22.91	126.1	Cluster 1
4	4	147.05	0	Cluster 2
5	5	96.6	52.92	Cluster 2
6	6	207.7	86.60	Cluster 2
7	7	155.32	50	Cluster 2
8	8	45	105.83	Cluster 1
9	9	242.54	99.5	Cluster 2

10	10	140.1	40	Cluster 2
11	11	147.05	0	Cluster 2
12	12	147.05	0	Cluster 2
13	13	151.74	0	Cluster 2
14	14	64.23	95.4	Cluster 1
15	15	33.54	150.33	Cluster 1
16	16	176.98	36.05	Cluster 2
17	17	30.41	117.05	Cluster 1
18	18	140.1	0	Cluster 2
19	19	91.24	58.31	Cluster 2
20	20	41.53	107.24	Cluster 1
21	21	0	147.054412	Cluster 1
22	22	70.9	80	Cluster 1
23	23	100.62	115.8	Cluster 1
24	24	157.8	0	Cluster 2
25	25	157.6	64.03	Cluster 2
26	26	149.41	40	Cluster 2
27	27	157.6	64.03	Cluster 2
28	28	149.41	40	Cluster 2
29	29	147.05	0	Cluster 2
30	30	65.8	91.7	Cluster 1
31	31	210.1	150	Cluster 2
32	32	195.3	50	Cluster 2
33	33	195.3	50	Cluster 2
34	34	109.20	111.80	Cluster 1
35	35	71.6	76.2	Cluster 1
36	36	149.75	40	Cluster 2
37	37	29.6	120.83	Cluster 1
38	38	110.6	48.98	Cluster 2
39	39	147.05	0	Cluster 2
40	40	140.44	38.73	Cluster 2

Berdasarkan matrik yang didapatkan pada tabel di atas maka didapatkan pengelompokan yang ditampilkan pada Tabel 4.4 sebagai berikut :

Tabel 4.4 Hasil Pengelompokan Data

Cluster1	Data 3, 8, 14, 15, 17, 20, 21, 22, 23, 30, 34, 35, dan 37
Cluster2	Data 1, 2, 4, 5, 6, 7, 9, 10, 11, 12, 13, 16, 18, 19, 24, 25, 26, 27, 28, 29, 31, 32, 33, 36, 38, 39, dan 40

Setelah didapatkan anggota dari setiap cluster kemudian akan di tentukan pusat cluster baru yang di hitung berdasarkan data anggota tiap-tiap cluster seperti yang ditunjukkan pada persamaan (4.2):

$$C_{kj} = \frac{\sum_{i=1}^p X_{ij}}{p}$$

(4.2)

Dari perhitungan menggunakan persamaan 4.2 di atas, maka didapatkan hasil pusat cluster dalam matrik pusat cluster baru yang dapat dilihat pada Tabel 4.5 dibawah ini:

Tabel 4.5 Pusat Cluster Baru Algoritma K-Means Clustering

Cluster1	36.92	7.7	16.54	11.54	0	7.7
Cluster2	136.3	8.52	34.81	18.52	1.5	16.7

Dataset pada penelitian ini akan diterapkan pendekatan algoritma K-Harmonic Means Clustering, dengan proses awal inisialisasi titik centroid sebanyak jumlah cluster secara random, yang ditampilkan pada Tabel 4.6 dibawah ini:

Tabel 4.6 Inisialisasi Titik Centroid

No	Item komponen	Replacement	Adjustment	Inspection	Clean up	Lubrication	Repair
21	Engine oil	10	0	5	0	0	0
29	Motor Fan	150	0	50	0	0	0

Dari penentuan inisialisasi titik centroid pada cluster secara random, selanjutnya hitung nilai fungsi anggota cluster atau Objective Function yang mendefinisikan proporsi dari data point  $X_i$  milik pusat  $C_l$  dengan persamaan (4.3)

$$KHM(X, C) = \sum_{i=1}^N \frac{K}{\sum_{i=1}^K \frac{1}{|X_i - C_l|^p}}$$

(4.3)

Hasil perhitungan untuk nilai fungsi tujuan ke-22 .....N terhadap dataset yang dapat dilihat pada Tabel 4.7 dibawah ini :

Tabel 4.7 Hasil Perhitungan Objective Function

No	Nilai Fungsi Ke Dataset	Nilai
1	Nilai fungsi pada dataset ke 1	28.6
2	Nilai fungsi pada dataset ke 2	29.03
3	Nilai fungsi pada dataset ke 3	24
4	Nilai fungsi pada dataset ke 4	225
5	Nilai fungsi pada dataset ke 5	68.6

6	Nilai fungsi pada dataset ke 6	92.31
7	Nilai fungsi pada dataset ke 7	128.6
8	Nilai fungsi pada dataset ke 8	35.3
9	Nilai fungsi pada dataset ke 9	206.9
10	Nilai fungsi pada dataset ke 10	56.25
11	Nilai fungsi pada dataset ke 11	225
12	Nilai fungsi pada dataset ke 12	225
13	Nilai fungsi pada dataset ke 13	225
14	Nilai fungsi pada dataset ke 14	42.9
15	Nilai fungsi pada dataset ke 15	240
16	Nilai fungsi pada dataset ke 16	79.41
17	Nilai fungsi pada dataset ke 17	48
18	Nilai fungsi pada dataset ke 18	225
19	Nilai fungsi pada dataset ke 19	100
20	Nilai fungsi pada dataset ke 20	50
21	Nilai fungsi pada dataset ke 21	20
22	Nilai fungsi pada dataset ke 22	28.23
23	Nilai fungsi pada dataset ke 23	100
24	Nilai fungsi pada dataset ke 24	150
25	Nilai fungsi pada dataset ke 25	62.1
26	Nilai fungsi pada dataset ke 26	78.3
27	Nilai fungsi pada dataset ke 27	62.1

28	Nilai fungsi pada dataset ke 28	78.3
29	Nilai fungsi pada dataset ke 29	225
30	Nilai fungsi pada dataset ke 30	66.7
31	Nilai fungsi pada dataset ke 31	225
32	Nilai fungsi pada dataset ke 32	240
33	Nilai fungsi pada dataset ke 33	240
34	Nilai fungsi pada dataset ke 34	200
35	Nilai fungsi pada dataset ke 35	80
36	Nilai fungsi pada dataset ke 36	56.25
37	Nilai fungsi pada dataset ke 37	240
38	Nilai fungsi pada dataset ke 38	28.8
39	Nilai fungsi pada dataset ke 39	225
40	Nilai fungsi pada dataset ke 40	29.03

Dari perhitungan fungsi anggota atau objective function diatas, peneliti mendapatkan nilai fungsi dari tiap-tiap dataset, yang selanjutnya nilai tersebut akan dikelompokkan sesuai inisialisasi penentuan titik cluster awal dengan jarak terdekat, dimana data dari dataset ke 21 disebut sebagai KHM 1 dan data dari dataset ke 29 disebut sebagai KHM 2. Maka diketahuilah dari nilai fungsi pada dataset tersebut akan masuk pada tiap-tiap anggota cluster yang dapat dilihat pada Tabel 4.8 dibawah ini:

Tabel 4.8 Jarak Terdekat Nilai Fungsi Dataset

No	Nilai Fungsi Ke Dataset	Nilai	Anggota Cluster
1	Nilai fungsi pada dataset ke 1	28.6	KHM1
2	Nilai fungsi pada dataset ke 2	29.03	KHM1
3	Nilai fungsi pada dataset ke 3	24	KHM1
4	Nilai fungsi pada dataset ke 4	225	KHM2
5	Nilai fungsi pada dataset ke 5	68.6	KHM1

6	Nilai fungsi pada dataset ke 6	92.31	KHM1
7	Nilai fungsi pada dataset ke 7	128.6	KHM1
8	Nilai fungsi pada dataset ke 8	35.3	KHM1
9	Nilai fungsi pada dataset ke 9	206.9	KHM2
10	Nilai fungsi pada dataset ke 10	56.25	KHM1
11	Nilai fungsi pada dataset ke 11	225	KHM2
12	Nilai fungsi pada dataset ke 12	225	KHM2
13	Nilai fungsi pada dataset ke 13	225	KHM2
14	Nilai fungsi pada dataset ke 14	42.9	KHM1
15	Nilai fungsi pada dataset ke 15	240	KHM2
16	Nilai fungsi pada dataset ke 16	79.41	KHM1
17	Nilai fungsi pada dataset ke 17	48	KHM1
18	Nilai fungsi pada dataset ke 18	225	KHM2
19	Nilai fungsi pada dataset ke 19	100	KHM1
20	Nilai fungsi pada dataset ke 20	50	KHM1
21	Nilai fungsi pada dataset ke 21	20	KHM1
22	Nilai fungsi pada dataset ke 22	28.23	KHM1
23	Nilai fungsi pada dataset ke 23	100	KHM1
24	Nilai fungsi pada dataset ke 24	150	KHM2
25	Nilai fungsi pada dataset ke 25	62.1	KHM1
26	Nilai fungsi pada dataset ke 26	78.3	KHM1
27	Nilai fungsi pada dataset ke 27	62.1	KHM1
28	Nilai fungsi pada dataset ke 28	78.3	KHM1
29	Nilai fungsi pada dataset ke 29	225	KHM2
30	Nilai fungsi pada dataset ke 30	66.7	KHM1
31	Nilai fungsi pada dataset ke 31	225	KHM2
32	Nilai fungsi pada dataset ke 32	240	KHM2
33	Nilai fungsi pada dataset ke 33	240	KHM2
34	Nilai fungsi pada dataset ke 34	200	KHM2
35	Nilai fungsi pada dataset ke 35	80	KHM1

36	Nilai fungsi pada dataset ke 36	56.25	KHM1
37	Nilai fungsi pada dataset ke 37	240	KHM2
38	Nilai fungsi pada dataset ke 38	28.8	KHM1
39	Nilai fungsi pada dataset ke 39	225	KHM2
40	Nilai fungsi pada dataset ke 40	29.03	KHM1

Berdasarkan jarak terdekat nilai fungsi dataset yang didapatkan pada Tabel 4.8 di atas, maka diketahui keanggotaan pada setiap pusat cluster yang ditampilkan pada Tabel 4.9 berikut ini:

Tabel 4.9 Hasil Pengelompokan Data

KHM1	1, 2, 3, 5, 6, 8, 10, 14, 16, 17, 20, 21, 22, 25, 26, 27, 28, 30, 35, 36, 38, dan 40
KHM2	4, 7, 9, 11, 12, 13, 15, 18, 19, 23, 24, 29, 31, 32, 33, 34, 37, dan 39

Setelah didapatkan keanggotaan pengelompokan data dari setiap cluster kemudian akan di tentukan nilai bobot  $W(X_i)$  berdasarkan persamaan (4.4)

$$W(x_i) = \frac{\sum_{l=1}^k ||x_i - c_l||^{-p-2}}{(\sum_{l=1}^k ||x_i - c_l||^{-p})^2}$$

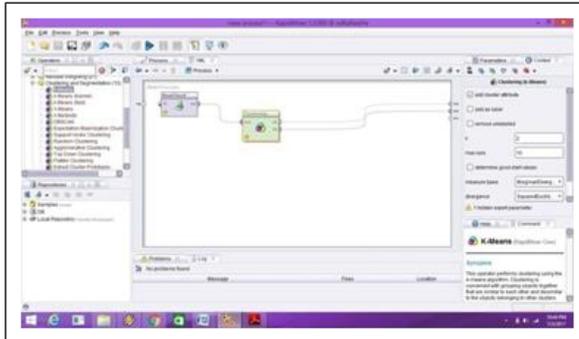
(4.4)

Hasil perhitungan dari nilai bobot  $W(X_i)$  yang mendefinisikan seberapa besar pengaruh data point  $X_i$  sehingga ditetapkan keanggotaan data  $X_i$  pada suatu cluster dengan titik pusat cluster yang dapat dilihat pada Tabel 4.10 dibawah ini:

Tabel 4.10 Nilai Fungsi bobot  $X_i$

	Nilai Titik Pusat Cluster
<i>K-Harmonic Means 1</i>	<b>52.01</b>
<i>K-Harmonic Means 2</i>	<b>202.53</b>

Data dari hasil penelitian ini, akan di implementasikan menggunakan RapidMiner untuk pemodelan algoritma *K-Means Clustering*, yang ditampilkan pada Gambar 4.1 dibawah ini:



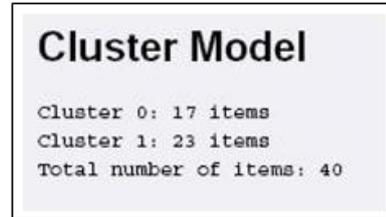
Gambar 4.1 Implementasi Dataset K-Means pada RapidMiner

Row No.	No	Item komponen	cluster	Replacement	Adjustment	Inspection	Clean-Up	Lubrication	Repair
1	1	Accu / Battery	cluster_1	100	0	10	10	0	0
2	2	Alternator	cluster_0	0	30	10	0	10	150
3	3	Air Filter	cluster_0	30	0	10	10	0	0
4	4	Bearing Release	cluster_1	150	0	50	0	0	0
5	5	Brake Shoe	cluster_0	80	40	40	40	0	0
6	6	Brake Drum	cluster_1	200	50	50	50	0	0
7	7	Brake Pad	cluster_1	150	0	50	50	0	0
8	8	Brake Fluid	cluster_0	50	0	10	20	0	0
9	9	Ball Joint and Boot	cluster_1	250	0	40	0	0	0
10	10	Bohlam Halogen	cluster_1	150	0	10	0	0	0
11	11	Bearing Wheel Front	cluster_1	150	0	50	0	0	0
12	12	Bearing Wheel Rear	cluster_1	150	0	50	0	0	0
13	13	Cover Clutch	cluster_1	150	0	50	0	0	0
14	14	Clutch Fluid	cluster_0	50	0	10	50	0	0
15	15	Charcoal Canister	cluster_0	0	0	40	0	0	0
16	16	Cross Joint Kopel	cluster_1	180	0	50	0	20	0
17	17	Differential Fluid	cluster_0	40	0	10	0	0	0
18	18	Disc Clutch	cluster_1	150	0	50	0	0	0
19	19	Drive Belt	cluster_1	100	0	20	0	0	0
20	20	Filter Air Conditioner	cluster_0	50	0	10	10	0	0
21	21	Engine Oil	cluster_0	50	0	5	0	0	0
22	22	Fuel Filter Out Tank	cluster_0	80	0	10	10	0	0
23	23	Injection Nozzle	cluster_0	0	100	20	0	0	0
24	24	Injection Pump	cluster_0	0	0	50	0	0	150
25	25	Master Clutch Cylinder Up	cluster_1	150	50	20	50	0	0
26	26	Master Clutch Cylinder Low	cluster_1	150	0	20	50	0	0
27	27	Master Brake Cylinder Up	cluster_1	150	50	20	50	0	0
28	28	Master Brake Cylinder Low	cluster_1	150	0	20	50	0	0
29	29	Motor Fan	cluster_1	150	0	50	0	0	0
30	30	Power Steering Fluid	cluster_0	50	0	20	50	0	0
31	31	Refrigerant AC	cluster_1	150	0	50	150	0	0
32	32	Shock Absorber Front	cluster_1	200	0	50	0	0	0
33	33	Shock Absorber Rear	cluster_1	200	0	50	0	0	0
34	34	Stator Assy	cluster_0	0	0	50	0	0	100
35	35	Radiator Coolant	cluster_0	80	0	20	0	0	0
36	36	Radiator	cluster_0	0	0	10	0	0	150
37	37	Transmission Fluid	cluster_0	40	0	0	0	0	0
38	38	Tire	cluster_1	120	10	10	0	0	0
39	39	Timing Belt	cluster_1	150	0	50	0	0	0
40	40	V-Belt	cluster_1	150	0	10	0	10	0

Gambar 4.2 Inisialisasi Cluster pada Dataset

Gambar 4.2 adalah hasil inisialisasi cluster yang diimplementasikan pada RapidMiner. Dengan inisialisasi jumlah cluster sebanyak 2 buah, maka didapatkan hasil dengan cluster yang terbentuk adalah 2 sesuai dengan pendefinisian nilai *K* maka jumlah cluster\_0 ada 17 item dan cluster\_1 ada 23 item dengan total jumlah data sebanyak 40 item yang dapat dilihat pada data hasil

cluster model *K-Means* Gambar 4.3 dibawah ini:

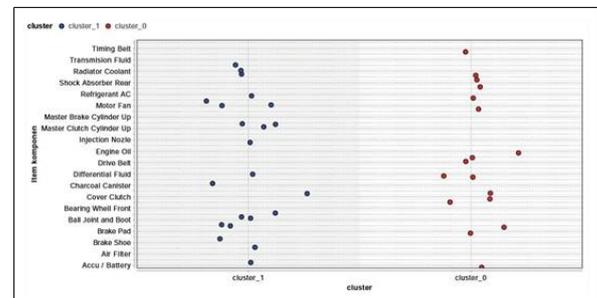


Gambar 4.3 Hasil Data Cluster Model K-Means

Dari data hasil cluster model *K-Means* dalam implementasi RapidMiner, didapatkan hasil antara jarak cluster dan centroid dari tiap-tiap attribute. Dimana nilai attribute yang memiliki nilai cluster tertinggi yaitu Replacemen dan Insepction pada cluster\_1 dan Replacemen dan Repair pada cluster\_0, dengan nilai yang bisa dilihat pada Tabel 4.11 dibawah ini:

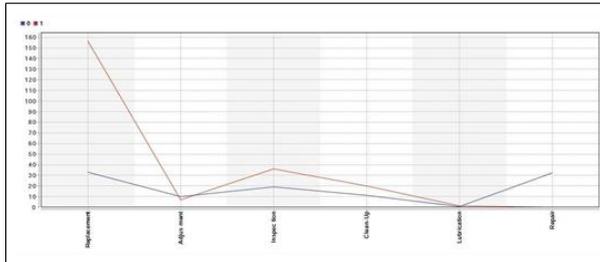
4.11 Hasil Perhitungan anantara Jarak Cluster dan Centroid

Attribute	cluster_0	cluster_1
Replacemen	32.941	156.522
Adjustment	10	6.957
Inspection	19.118	36.087
Clean-Up	11.176	20
Lubrication	0.588	1.304
Repair	32.353	0



Gambar 4.4 Titik-titik Centroid Cluster Berdasarkan Item Komponen

Gambar 4.4 adalah jarak antara titik centroid ke titik-titik centroid lainnya berdasarkan tiap-tiap item komponen, dimana cluster\_1 mendominasi titik yang memiliki jarak terdekat antara item komponen dibandingkan dengan cluster\_0.



Gambar 4.5 Grafik Data Attribute K-Means Clustering

Gambar 4.5 adalah Grafik data attribute K-Means clustering dari tiap-tiap cluster, yang diperoleh dari hasil perhitungan antara jarak cluster dan centroid disajikan pada Tabel 4.11. Dimana cluster\_0 memiliki 2 attribute yaitu Replacement dan Repair yang memiliki nilai tertinggi pada angka 32.9% dan 32.3%. Sedangkan untuk cluster\_1 memiliki 2 attribute yang berbeda dengan cluster\_0 yaitu Replacement dan Inspection yang memiliki nilai tertinggi pada 156.5% dan 36%.

Peneliti selanjutnya melakukan pengujian dengan mengukur tingkat accuracy dengan menggunakan Confucion Matrix dari data hasil prediksi positive yang benar sebesar 220.87, prediksi positive yang salah sebesar 80.4, prediksi negative yang benar sebesar 106.176, dan prediksi negative yang salah 216.35 seperti yang ditampilkan pada Tabel 4.12 dibawah ini :

Tabel 4.12 Nilai-nilai Prediksi

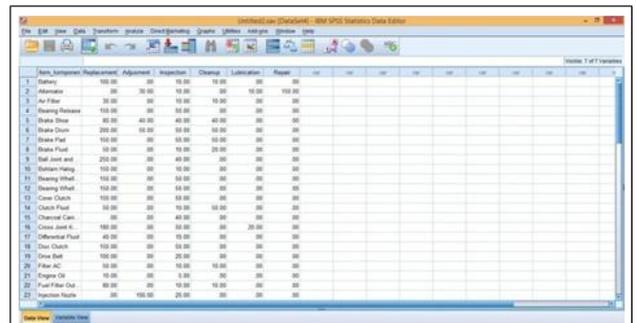
		Target	
		Positive	Negative
Model	Positive	220.87	80.4
	Negative	106.176	216.35

Tabel nilai hasil prediksi dapat di ketahui dengan jelas nilai dari masing-masing prediksinya yang dapat dilihat pada Tabel 4.13 dibawah ini:

Tabel 4.13 Nilai Hasil Prediksi

Confucion Matrix		Taget		
		Positive	Negative	
Model	Positive	220.87	80.4	Positive Predictive Value : 73%
	Negative	106.176	216.35	Negative Predictive Value : 67%
		Sensivity : 67%	Specificity : 73%	Accuracy = 70%

Hasil pengolahan data dengan IBM SPSS Statistic pada pengolahan algoritma K-Harmonic Means Clustering yang dapat dilihat pada Gambar 4.6 dibawah ini:



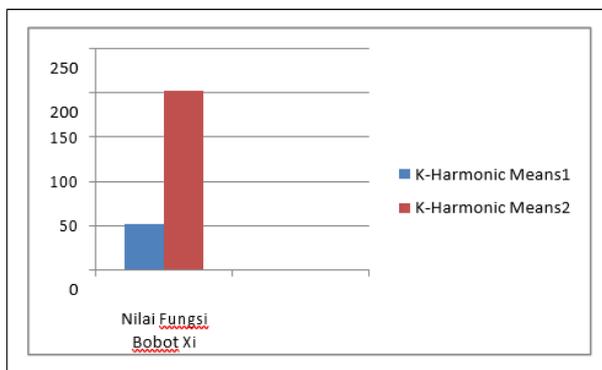
Gambar 4.6 Implementasi Dataset K-Harmonic Means ke IBM SPSS Statistic

Dari hasil implementasi IBM SPSS statistic diatas didapati hasil deskripsi statistic dari K-Harmonic Means clustering untuk mengetahui nilai *Mean* dan *Standar Deviasi*. Dimana K-Harmonic Means1 memiliki data statistic untuk nilai *Mean* 211.5100 dan *Standar Deviation* dengan nilai 291.76640 dan K-Harmonic Means2 dengan nilai *Mean* 3.2242 dan nilai *Standar Deviation* sebesar 4.51721 yang ditampilkan pada Tabel 4.14 dibawah ini.

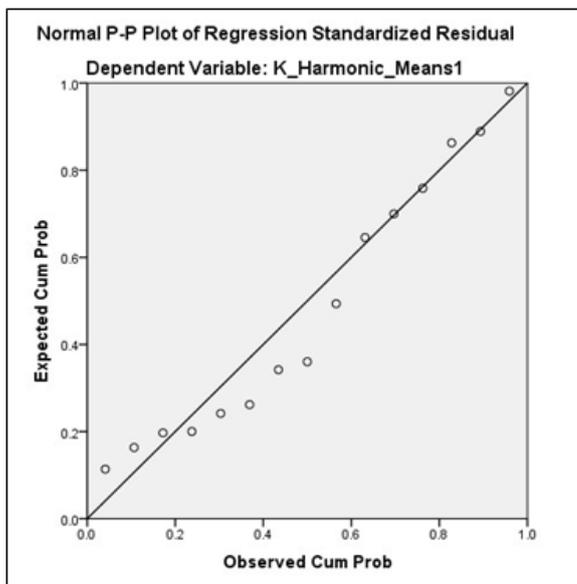
Tabel 4.14 Deskripsi Statistik K-Harmonic Means

Descriptive Statistics			
	Mean	Std. Deviation	N
K_Harmonic_Means1	211.5100	291.76640	2
K_Harmonic_Means2	3.2242	4.51721	2

Gambar 4.7 merupakan tampilan Grafik Nilai fungsi dari bobot  $x_i$ , dimana K-Harmonic Means2 memiliki nilai yang tinggi dibandingkan dengan K-Harmonic Means1, yang dapat dilihat pada gambar dibawah ini.



Gambar 4.7 Grafik Nilai Fungsi Bobot Xi



Gambar 4.8 Regression Standardized Residual

Gambar 4.8 merupakan Regression Standardized Residual dari implementasi SPSS Statistic dari variable K-Harmonic Means1 dimana titik-titik pada variable Observed Cum Prob lebih mengakuisisi titik yang lebih banyak di banding titik pada variable Expected Cum Prob.

Peneliti selanjutnya melakukan pengujian dengan mengukur tingkat accuracy dari hasil implementasi IBM SPSS Statistic dengan menggunakan Confucion Matrix dari data hasil prediksi positive yang benar sebesar 52.01, prediksi positive yang salah sebesar 211.51, prediksi negative yang benar sebesar 202.53, dan prediksi negative yang salah 3.22 seperti yang ditampilkan pada Tabel 4.15 dibawah ini:

Tabel 4.15 Nilai-nilai Prediksi

		Target	
		Positive	Negative
Model	Positive	202.53	3.22
	Negative	52.01	211.51

Tabel nilai hasil prediksi dapat di ketahui dengan jelas nilai dari masing-masing prediksinya yang dapat dilihat pada Tabel 4.16.

Tabel 4.16 Nilai Hasil Prediksi

Confucion Matrix		Taget		
		Positive	Negative	
Model	Positive	202.53	3.22	Positive Predictive Value : 98%
	Negative	52.01	211.51	Negative Predictive Value : 77%
		Sensivity : 53%	Specificity : 98%	Accuracy = 88%

Dari kedua hasil penelitian algoritma K-Means Clustering dengan implementasi RapidMiner dan algoritma K-Harmonic Means dengan implementasi IBM SPSS Statistic, dan hasil keduanya diujikan dengan confusion matrix maka didapatkan hasil komparasi pada tiap-tiap algoritma yang ditunjukkan pada Tabel 4.17 dibawah ini :

Tabel 4.17 Hasil Komparasi Akhir Algoritma K-Means dan K-Harmonic Means

Dataset	Positive Predictive		Negative Predictive		Sensitivity		Specificity		Accuracy	
	KM	KHM	KM	KHM	KM	KHM	KM	KHM	KM	KHM
Komponen Item	73%	98%	67%	77%	67%	53%	73%	98%	70%	88%

Dari hasil komparasi akhir algoritma K-Means Clustering dan K-Harmonic Means Clustering yang ditampilkan pada tabel 4.17 diatas, hasil Positive Predictive, Negative Predictive, Specificity, dan Accuracy untuk KHM lebih baik dibanding KM, namun untuk hasil Sensivity KHM kurang baik dibanding KM. Semakin baik hasil akhir accuracy yang diperoleh, maka accuracy yang dimiliki semakin baik (McDuffe,2010).

## 5 KESIMPULAN

Berdasarkan hasil eksperimen, dapat disimpulkan sebagai berikut :

1. Hasil dari penerapan model algoritma K-Means Clustering dengan implementasi RapidMiner didapatkan jumlah cluster sebanyak 2 buah, yang terdiri dari cluster\_0 sebanyak 17 item dan cluster\_1 sebanyak 23 item dengan total jumlah data sebanyak 40 item.
2. Hasil dari penerapan model algoritma K-Harmonic Means Clustering dengan implementasi IBM SPSS Statistic didapatkan deskripsi statis untuk K-

Harmonic Means1 211.5100 dan K-Harmonic Means2 3.2242.

3. Grafik dengan model algoritma K-Means Clustering menunjukkan item replacemen memiliki tingkat tertinggi pada cluster\_1 dan cluster\_0 pada repair. Sedangkan pada pemodelan algoritma K-Harmonic Means Clustering grafik tertinggi dimiliki oleh K-Harmonic Means2.

4. Hasil pengujian dengan menggunakan Confusion Matrix untuk model algoritma K-Means Clustering didapati prediksi positive = 73%, prediksi negative = 67%, sensitivity = 67%, specificity = 73%, dan accuracy = 70%. Sedangkan untuk model algoritma K-Harmonic Means Clustering didapati prediksi positive = 98%, prediksi negative = 77%, sensitivity = 53%, specificity = 98%, dan accuracy = 88%.

## REFERENSI

- Agustina, S., Yhudo, D., Santoso, H., Marnasusanto, N., Tirtana, A., & Khusnu, F., Clustering Kualitas Beras Berdasarkan Ciri Fisik Menggunakan Metode K- Means Algoritma (2014).
- Asti, M. M., & Prasetyawan, Y., Penjadwalan Preventive Maintenance berdasarkan Perspektif, 1 (6) - June, 2013, 1012-1108.
- Barlow, R., & Hunter, L., Optimum Preventive Maintenance Policies. Operations Research, 8 (1) - June, 1960, 2241-1082.
- Chen, M., Mizutani, S., & Nakagawa, T., International Journal of Reliability, Quality and Safety Engineering, Random and age replacement policies. 17 (1) - January, 2010, S0218539310003652
- Curcuro, G., Galante, G., & Lombardo, A., Reliability Engineering and System Safety, A predictive maintenance policy with imperfect monitoring. 95 (9) - April, 2010.

- Endrenyi, J., & Anders, G. J., IEEE Power and Energy Magazine, Maintainability, maintenance, and reliability for engineers, 4, Informa CRC Press, 2006.
- Fei, R., Mobley, R. K., & Wikoff, D. J., Maintenance Engineering Handbook., Tissue engineering Part C Methods, 7, The McGraw Hill Companies, 2008, New York - USA.
- Gaikindo. (2016). Domestic Auto Production By Category 2015.
- Hillier, F. S., & Editor, S., Handbook of production scheduling, Jefferey W. Hermann, 2006, University of Maryland - USA.
- Joel Levitt, Complete Guide to Preventive and Predictive Maintenance. Industrail Press Inc, Second Edition, Joel Levitt, 2011, New York.
- Kamber, M., & Han, J., Data Mining : Concepts and Techniques University of Illinois at Urbana-Champaign, 2nd, Jiawei Han, 2008, University of Illinois at Urbana - USA.
- Kenne, J. P., & Boukas, E. K., Mathematical and Computer Modelling, Hierarchical Control of production and maintenance rates in a Multiple- product manufacturing systems, 9 (1) - February, 2003, S0895-7177.
- Kumar, S. A., & Suresh, N., Production and Operations Management, 2nd, New Age International Publishers, 2008, New Delhi - India.
- Lin, Z. L., Huang, Y. S., & Fang, C. C., Reliability Engineering and System Safety, Non-periodic preventive maintenance with reliability thresholds for complex repairable systems, 136 (1) - December, 2015, 0951-8320.
- Mishra, R. C., & Pathak, K., Maintenance Engineering and Management, 2nd, PHI Learning Private Limited, 2012, New Delhi - India.
- Mobley, R. K., An introduction to predictive maintenance, 2nd, Butterworth Heinemann, 2002, Amsterdam.
- Nowlan, F., Reliability Centered Maintenance, U.S Deartment of Commerce, 1978, San Francisco - california.
- Nyman, D., & Levitt, J., Maintenance planning and scheduling coordination, 2nd , Industrial Press, 2001, New York.
- Oded Maimon, L. R., Data Mining and Knowledge Discovery Handbook, 2nd , Heinemann, 2010, London.
- OICA. (2016). Word Motor Vehicle Production By Country And Type, 27.
- Oliver, R., & Rust, R., Service quality: new directions in theory and practice, First, Sage Publications, 1994, London.
- Ong, J. O., Implementasi Algoritma K-Means Clustering untuk Menentukan Strategi Marketing, 1 - April, 2013.
- Pham, H., & Wang, H., European Journal of Operational Research, Imperfect maintenance, 94 (3), - March, 1996, 0377-2217.
- Purnama, J., Putra, Y. A., & Kalamollah, M., Metode Age Replacement Digunakan Untuk Menentukan Interval Waktu Perawatan Mesin Pada Armada BUS, 1, - Maret, 2015, 978-602-98569-1-0.
- Rasindyo, M. R., Kusmaningrum, & Helianty, Y., Analisa Kebijakan Perawatan Mesin Cincinnati Dengan Menggunakan Metode RCM Di PT. DIRGANTARA INDONESIA, 3(1), Januari, 2015, ISSN 2238-5081.

- Russell, S. J., & Norvig, P., *Artificial Intelligence: A Modern Approach*. Artificial Intelligence, 3th, Artificial Intelligence, 2010, New Jersey.
- Sahin, I., & Polatoglu, H., *Quality, Warranty and Preventive Maintenance*. First, Springer Science & Business Media, 1998, New York.
- Saikhu, A., & Okta, Y., Perbandingan Kinerja Metode K-Harmonic Means dan Particle Swarm Optimization untuk Klasterisasi Data, 7 (2), - Juli, 2002, 1978-0087.
- Syahrudin., Analisis Sistem Perawatan Mesin Menggunakan Metode Reliability Centered Maintenance ( RCM ) Sebagai Dasar Kebijakan Perawatan yang Optimal di PLTD “ X .”, 1 (1) - Oktober, 2013, 2338-6649.
- Thearling, K., & Ph, D., *An Introduction to Data Mining*, 1 (47) - Februari, 2005. Wai-Fah Chen, Lian, & D., *Bridge Engineering Handbook 2nd CONSTRUCTION AND MAINTENANCE*, 2nd, CRC Press, 2014, London.
- Wang, H., *European Journal of Operational Research*, A survey of maintenance policies of deteriorating systems. 139 (3) - November, 2002, S0377-2217.
- Wang, Y., Deng, C., Wu, J., Wang, Y., & Xiong, Y., *Engineering Failure Analysis*, A corrective maintenance scheme for engineering equipment, 36 (1) - Oktober, 2014, 1108-1016.
- Wardhani, A. K., *Jurnal Transformatika*, K-Means Algorithm Implementation for Patients Disease in Kajen Clinic of Pekalongan, 14 (1) - Juli, 2016, 30–37.
- Wicaksana, I. W. S., *Belajar Data Mining dengan RapidMiner*, First, Remi Sanjaya, 2013, Jakarta - Indonesia.
- Yang, F., Sun, T., & Zhang, C., *Expert Systems With Applications*, Expert Systems with Applications An efficient hybrid data clustering method based on K- harmonic means and Particle Swarm Optimization, 36 (6) - March, 2009, 9847–9852.
- Yoo, J., & Lee, I. S., *Computers & Industrial Engineering*, Parallel machine scheduling with maintenance activities. 101 - September, 2016, 1016-1020.
- Zhang, B., Hsu, M., & Dayal, U., *Clustering Algorithm K -Harmonic Means -A Data Clustering Algorithm*, 1 (26) - June, 1999.
- Zhao, X., Al-khalifa, K. N., Magid, A., & Nakagawa, T., *Reliability Engineering and System Safety*, Age Replacement Models : A Summary with New Perspectives and Methods. 1 (161) - Januari, 2017.