Clustering Terhadap Indeks Prestasi Mahasiswa STMIK Akakom Menggunakan K-Means

Sri Redjeki[1)], Andreas Pamungkas[2)], Hastin Al-fatah[3)]

[1)2)3)]*STMIK AKAKOM YOGYAKARTA*
e-mail : dzeky@akakom.ac.id

Abstrak

Clustering k-means merupakan salah satu metode *Data Mining* yang bersifat tanpa arahan (*unsupervised*). *Cluster*ing merupakan cara memasukkan suatu pola yang diamati ke suatu kelas pola yang belum diketahui dan disebut sebagai kluster pola. Ada dua jenis data *cluster*ing yang sering dipergunakan dalam proses pengelompokan data yaitu *hierarchical* (hirarki) data *cluster*ing dan *non-hierarchical* (non hirarki) data *cluster*ing. Pada penelitian ini menggunakan pendekatan hirarki dengan *partioning clustering.*

Obyek dari penelitian ini menggunakan data indeks prestasi mahasiswa yang berupa IPS dan IPK. Nilai IPS yang digunakan yaitu semester ganjil dan semester genap pada T.A 2007/2008 dan 2008/2009, sedangkan nilai IPK yang digunakan adalah IPK pada saat semester ganjil 2009/2010. Hasil dari penelitian ini menunjukkan bahwa cluster akhir untuk T.A 2007/2008 mempunyai kecenderungan yang sama. Sedangkan untuk cluster akhir untuk T.A. 2008/2009 mempunyai kecenderungan yang cukup berbeda. Proses *clustering* data tiap semester dilakukan dalam dua kali percobaan agar dapat dibandingkan nilai tengah terbaiknya.

Kata Kunci : *Clustering k-means, nilai tengah, indeks prestasi mahasiswa, STMIK AKAKOM.*

1. Pendahuluan

Sebuah perguruan tinggi yang baik sangat dipengaruhi oleh prestasi mahasiswa yang ada didalamnya. Mahasiswa merupakan obyek dari proses pembelajaran yang ada pada perguruan tinggi sehingga apabila prestasi mahasiswa baik maka ukuran ini dapat dijadikan indikator bahwa proses pada perguruan tinggi tersebut telah berjalan dengan baik. Perlunya analisa mengenai prestasi mahasiswa dalam hal ini nilai indeks prestasi sangat bermanfaat agar kualitas sebuah perguruan tinggi dapat dipertahankan.

STMIK AKAKOM menyadari bahwa analisa mengenai indeks prestasi mahasiwa secara periodik sangatlah bermanfaat untuk mengendalikan proses yang ada pada tiap periodik. STMIK AKAKOM menyadari bahwa input mahasiswa baru setiap tahunnya mempunyai kualitas yang berbeda-beda sehingga akan mempengaruhi proses pembelajaran yang ada agar dapat mempertahankan kualitas yang telah ada sehingga diperlukan sebuah analisa dengan melakukan pengelompokan (cluster) indeks prestasi kedalam kelompok kelompok tertentu. Clustering indeks prestasi ini dapat dilakukan secara periodik sehingga dapat dibandingkan hasil cluster secara periodiknya.

Clustering merupakan salah satu metode *Data Mining* yang bersifat *unsupervised* (tidak terawasi). Terdapat dua jenis data clustering yang sering digunakan untuk pengelompokkan data yaitu hirarki data clustering dan non-hirarki data clustering. K-means merupakan salah satu metode data clustering non-hirarki yang berusaha mempartisi data yang ada kedalam kelompok. Dari permasalahan diatas peneliti akan melakukan penelitian untuk melakukan clustering terhadap indeks prestasi mahasiswa STMIK AKAKOM menggunakan metode K-means.

2. Tinjauan Pustaka

Penelitian ini banyak mengacu pada tulisan-tulisan mengenai Clustering antara lain:

a. Yudi Agusta,Ph.D dengan judul K-Means, penerapan, permasalahan dan metode terkait.
b. Noor Rindho&Suzuki Syofian dengan judul Implementasi Data Mining dengan metode

Clustering untuk melakukan *Competitive Intelligence* Perusahaan.

c. Vidya Ayuningtias dengan judul Pengkategorian Hasil Pencarian Dokumen dengan Clustering.

3. Landasan Teori

a. Data Mining

Data Mining memang salah satu cabang ilmu komputer yang relatif baru. Dan sampai sekarang orang masih memperdebatkan untuk menempatkan *data mining* di bidang ilmu mana, karena *data mining* menyangkut *database*, kecerdasan buatan (*artificial intelligence*) dan statistik, Ada pihak yang berpendapat bahwa *data mining* tidak lebih dari *machine learning* atau analisa statistik yang berjalan di atas *database*. Namun pihak lain berpendapat bahwa *database* berperanan penting di *data mining* karena *data mining* mengakses data yang ukurannya besar (bisa sampai terabyte) dan disini terlihat peran penting *database* terutama dalam optimisasi *query*-nya. Definisi *data mining* (Jiawei, 2000) adalah proses mengekstraksi pola-pola yang menarik (tidak remeh-temeh, implisit, belum diketahui sebelumnya, dan berpotensi untuk bermanfaat) dari data yang berukuran besar. Terdapat beberapa istilah yang mempunyai kemiripan dengan *data mining*, yaitu ekstraksi pengetahuan, analisis pola, pengerukan data, dan lain-lain. Beberapa buku menulis bahwa *data mining* merupakan sinonim dari istilah *knowledge discovery in database* (KDD) (Jiawei,2000).

Data mining muncul berdasarkan fakta bahwa pertumbuhan data yang sangat pesat, tetapi miskin dengan pengetahuan. Alasan memilih *data mining* dibanding analisis data secara tradisional adalah :

a. D*ata mining* mampu menangani jumlah data kecil sampai data yang berukuran terabyte,
b. Mampu menangani data yang mempunyai banyak dimensi, yaitu puluhan sampai ribuan dimensi,
c. Mampu menangani data dengan kompleksitas yang tinggi, misalnya data stream, data sensor, data *spasial*, teks, data web, dan lain-lain.

Proses data mining dari basis data sampai pada user dapat dilihat pada gambar 1.

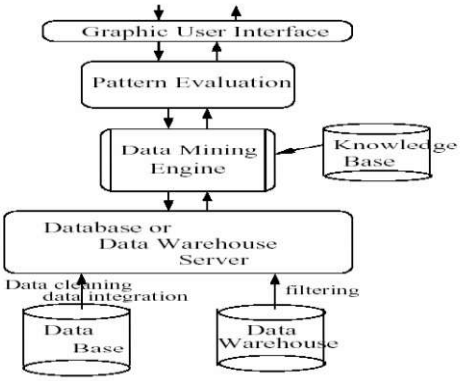

Gambar 1. Arsitektur data mining (Jiawei Han, 2000)

Contoh aplikasi data mining paling banyak digunakan dalam melakukan analisis dan manajemen pasar, manajemen keuangan, industri telekomunikasi, *text mining* dan *web mining*, *stream data mining,* analisis bioinformatika dan biodata, dan masih banyak lagi.

b. *Cluster*ing

Data *Cluster*ing merupakan salah satu metode *Data Mining* yang bersifat tanpa arahan (*unsupervised*). Ada dua jenis data *cluster*ing yang sering dipergunakan dalam proses pengelompokan data yaitu *hierarchical* (hirarki) data *cluster*ing dan *non-hierarchical* (non hirarki) data *cluster*ing. *Cluster*ing merupakan cara memasukkan suatu pola yang diamati ke suatu kelas pola yang belum diketahui dan disebut sebagai kluster pola. Tujuan dari *clustering (unsupervised classification)* adalah berusaha untuk mengelompokkan data dalam ruang ciri (*feature space*) secara natural ke dalam sejumlah cluster (Pedrycz, witold 2005).

Cluster merupakan suatu kelompok yang homogen, dimana tiap unit di dalamnya memiliki kemiripan satu sama lain. Untuk membentuk *cluster*ing dari sekumpulan data, maka kriteria dari kluster harus mempunyai kumpulan data yang homogen dan tidak serupa dengan kumpulan data lainnya, sedangkan *cluster* yang berbeda secara umum akan mengarah kepada kluster yang berbeda pula. Aplikasi dari *Cluster*ing antara lain: *engineering, bioinformatics, social sciences (sociology, archeology), medicine sciences (psychiatry, pathology*), data dan *web mining*.

c. K-Means

K-Means merupakan metode klasterisasi yang paling terkenal dan banyak digunakan di berbagai bidang karena sederhana, mudah diimplementasikan, memiliki kemampuan untuk mengklaster data yang besar, mampu menangani data outlier, dan kompleksitas waktunya linear O(nKT) dengan n adalah jumlah dokumen, K adalah jumlah kluster, dan T adalah jumlah iterasi. *K-Means* merupakan salah satu metode data *cluster*ing non hirarki yang berusaha mempartisi data yang ada ke dalam bentuk satu atau lebih *cluster*/kelompok yang berbeda. Dengan *partitioning* secara iteratif, K-Means mampu meminimalkan rata-rata jarak setiap data ke klasternya. Metode ini dikembangkan oleh Mac Queen pada tahun 1967. Metode ini mempartisi data ke dalam *cluster*/kelompok sehingga data yang memiliki karakteristik yang sama dikelompokkan ke dalam satu *cluster* yang sama dan data yang mempunyai karakteristik yang berbeda dikelompokkan ke dalam kelompok yang lain.

Adapun tujuan dari data *cluster*ing ini adalah untuk meminimalisasikan *objective function* yang diset dalam proses *cluster*ing, yang pada umumnya berusaha meminimalisasikan variasi di dalam suatu *cluster* dan memaksimalisasikan variasi antar *cluster*.

***d.* Algoritma K-Means**

Dasar algoritma K-means adalah sebagai berikut (Budi Santoso, 2007):

1. Tentukan nilai k sebagai jumlah klaster yang ingin dibentuk.
2. Bangkitkan k centroid (titik pusat klaster) awal secara random.
3. Hitung jarak setiap data ke masing-masing centroid menggunakan rumus antar dua objek yaitu Euclidean Distance.
4. Kelompokkan setiap data berdasarkan jarak terdekat antara data dengan centroidnya.
5. Tentukan posisi centroid baru (*k C*) dengan cara menghitung nilai pusat dari data-data yang ada pada centroid yang sama. Dimana *k n* adalah jumlah dokumen dalam *cluster* k dan *i d* adalah dokumen dalam *cluster* k.
6. Kembali ke langkah 3 jika posisi centroid baru dengan centroid lama tidak sama.

Adapun karakteristik dari algoritma K-Means salah satunya adalah sangat sensitif dalam penentuan titik pusat awal klaster, karena K-Means membangkitkan titik pusat klaster awal secara random. Pada saat pembangkitan awal titik pusat yang random tersebut mendekati solusi akhir pusat klaster, K-Means mempunyai posibilitas yang tinggi untuk menemukan titik pusat klaster yang tepat. Sebaliknya, jika awal titik pusat tersebut jauh dari solusi akhir pusat klaster, maka besar kemungkinan ini menyebabkan hasil pengelompokkan yang tidak tepat. Akibatnya K-Means tidak menjamin hasil pengelompokkan yang unik. Inilah yang menyebabkan metode K-Means sulit untuk mencapai optimum global, akan tetapi hanya minimum lokal. Selain itu, algoritma K-Means hanya bisa digunakan untuk data yang atributnya bernilai numerik.

e. Permasalahan K-Means

Beberapa permasalahan yang sering muncul pada saat menggunakan metode *K-Means* untuk melakukan pengelompokan data adalah:

1. Ditemukannya beberapa model *cluster*ing yang berbeda
2. Pemilihan jumlah *cluster* yang paling tepat
3. Kegagalan untuk *converge*
4. Pendeteksian *outliers*
5. Bentuk masing-masing *cluster*
6. Masalah *overlapping*

Keenam permasalahan ini adalah beberapa hal yang perlu diperhatikan pada saat menggunakan *K-Means* dalam mengelompokkan data. Permasalahan 1 umumnya disebabkan oleh perbedaan proses inisialisasi anggota masing-masing *cluster*. Proses initialisasi yang sering digunakan adalah proses inisialisasi secara random. Dalam suatu studi perbandingan (Pena, 1999), proses inisialisasi secara random mempunyai kecenderungan untuk memberikan hasil yang lebih baik dan independent, walaupun dari segi kecepatan untuk *converge* lebih lambat. Permasalahan 2 merupakan masalah laten dalam metode *K-Means*. Beberapa pendekatan telah digunakan dalam menentukan jumlah *cluster* yang paling tepat untuk suatu *dataset* yang dianalisa termasuk di antaranya *Partition Entropy (PE)* dan *GAP Statistics* (Tibshirani, 2000). Satu hal yang patut diperhatikan mengenai metode-metode ini adalah pendekatan yang digunakan dalam mengembangkan metode-metode tersebut tidak

sama dengan pendekatan yang digunakan oleh *K-Means* dalam mempartisi data items ke masing-masing *cluster*.

Perpindahan suatu data ke suatu *cluster* tertentu dapat mengubah karakteristik model *cluster*ing yang dapat menyebabkan data yang telah dipindahkan tersebut lebih sesuai untuk berada di *cluster* semula sebelum data tersebut dipindahkan. Demikian juga dengan keadaan sebaliknya. Kejadian seperti ini tentu akan mengakibatkan pemodelan tidak akan berhenti dan kegagalan untuk *converge* akan terjadi.

4. Hasil dan Pembahasan

a. Ploting Data Indeks Prestasi Mahasiswa

Data indeks prestasi yang digunakan pada analisa cluster k-means meliputi indeks prestasi semester (IPS) ganjil dan genap T.A 2007/2008 dan T.A 2008/2009, sedangkan nilai indeks prestasi kumulatif (IPK) yang digunakan merupakan indeks prestasi kumulatif pada saat semester Ganjil T.A 2009/2010. Total data yang digunakan pada penelitian ini sebanyak 1227 mahasiswa. Gambar 2 sampai gambar 5 menunjukkan sebaran data nilai indeks prestasi mahasiswa selama empat semester .

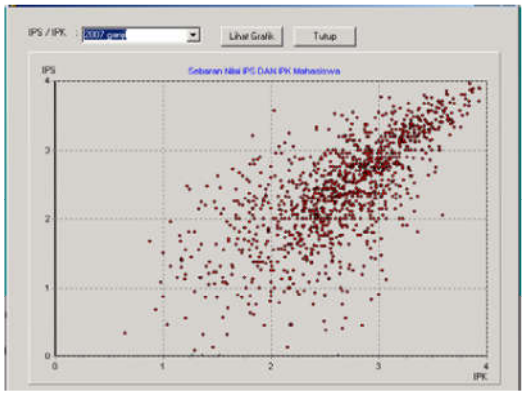

Gambar 2. Data Indeks Prestasi Semester Ganjil 2007/2008

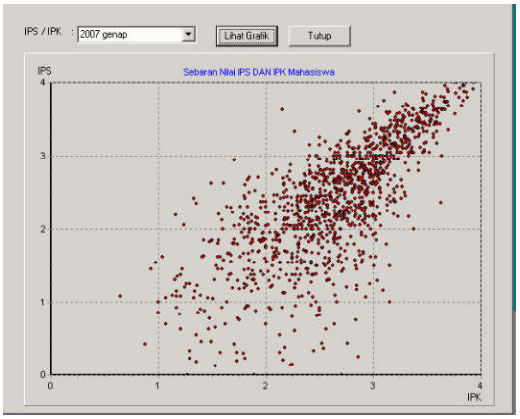

Gambar 3. Data Indeks Prestasi Semester Genap 2007/2008

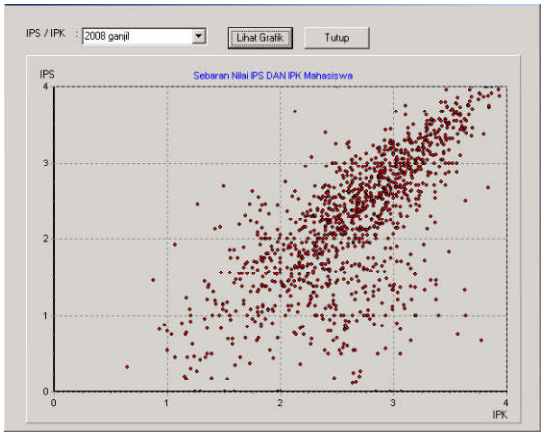

Gambar 4. Data Indeks Prestasi Semester Ganjil 2008/2009

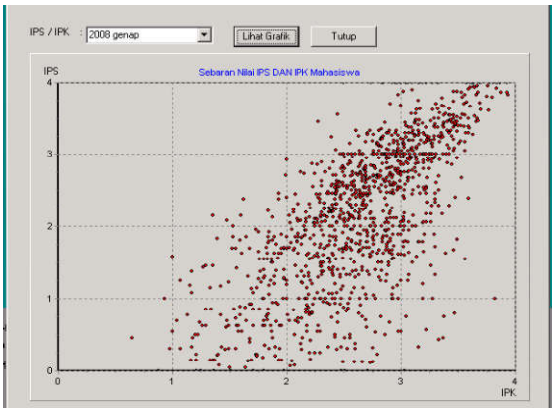

Gambar 5. Data Indeks Prestasi Semester Genap 2008/2009

Dari hasil ploting data untuk empat semester dapat terlihat bahwa pada T.A 2007/2008 untuk semester ganjil dan genap mempunyai pola yang sama, hal ini dapat dikatakan bahwa indeks prestasi IPS terhadap IPK untuk T.A 2007/2008 relatif sama dan data cenderung mengumpul pada garis linier antara IPS dan IPK (gambar 1 dan gambar.2). Hal ini menunjukkan proses yang terjadi masih relatif normal karena hubungan antara data IPS terhadap IPK mempunyai kecenderungan garis yang linier.

Sedangkan untuk data indeks prestasi pada tahun 2008/2009 terdapat perbedaan yang cukup signifikan antara semester ganjil dan semester genap, hal ini terlihat pada sebaran data yang terjadi pada semester genap yang cenderung lebih banyak berada dibawah garis linier (gambar 5). Ploting data seperti ini diasumsikan bahwa nilai IPS mahasiswa pada semester genap 2008/2009 kurang baik dibandingkan semester ganjil 2008/2009. Banyak faktor yang menentukan mengenai kondisi data pada periode ini, antara lain beban mahasiswa yang cukup besar, proses penilaian kurang representatif dan proses pembelajaran belum maksimal.

Data indeks prestasi mahasiswa pada semester ganjil 2008/2009 dibandingkan dengan indeks prestasi T.A 2007/2008 masih cukup baik T.A 2007/2008, hal ini dapat dilihat pada sebaran data pada semester ganjil 2008/2009 yang cukup banyak berada dibawah garis linier (gambar 4).

b. Hasil Analisa K-Means

Setelah melakukan ploting data terhadap nilai IPS dan IPK untuk masing-masing semester, maka dilakukan pengelompokan untuk masing-masing semester menjadi 3 cluster. Jumlah cluster sebanyak 3 dikarenakan rata-rata range indeks prestasi mahasiswa berada

pada nilai 1 sampai 4. Dari range tersebut akan dibagi menjadi 3 kelompok, sehingga ditentukan cluster sebanyak 3. Untuk masing-masing semester akan dilakukan dua kali perhitungan k-means sehingga kita dapat membedakan hasil clustering terutama nilai akhir dari masing-masing cluster. Untuk setiap semester dilakukan percobaan dua kali, sehingga dapat dibandingkan hasil untuk masing-masing percobaan.

b.1. Data Semester Ganjil 2007/2008

Untuk masing-masing percobaan hasil akhir cluster dapat dilihat pada gambar 5a dan 5b.

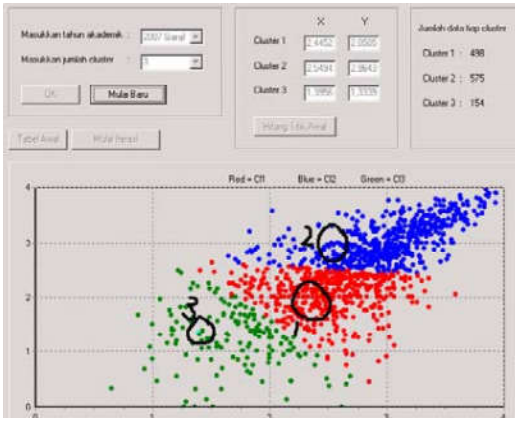

Gambar 5a. Hasil Cluster (percobaan 1)

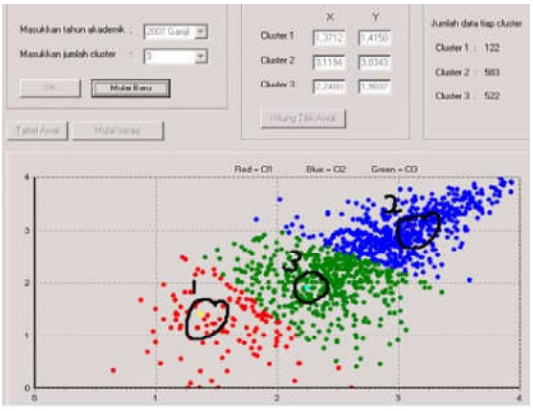

Gambar 5b. Hasil Cluster (percobaan 2)

Perbedaan kedua percobaan untuk semester ganjil 2007/2008 dapat dilihat pada tabel 1. Pada tabel tersebut terlihat bahwa nilai tengah terbaik ditunjukkan oleh percobaan kedua.

Tabel 1. Perbandingan K-Means Semester Ganjil 2007/2008

Hasil K-means	CL1		CL2		CL3	
	IPK	IPS	IPK	IPS	IPK	IPS
Nilai tengah AWAL1	1.3	2.7	2.8	3.3	3	1.2
Nilai tengah AKHIR1	2.4	2.05	2.5	2.96	1.39	1.33
Jumlah Data awal 1	173		695		359	
Jumlah Data akhir 1	498		575		154	
Nilai tengah AWAL 2	0.1	2.3	3	0.1	2	2.5
Nilai tengah AKHIR2	1.37	1.42	3.12	3.03	2.25	1.9
Jumlah Data awal 2	10		77		1140	
Jumlah Data akhir 2	122		583		522	

b.2. Data Semester Genap 2007/2008

Hasil akhir dari cluster untuk semester genap dengan dua kali percobaan dapat dilihat pada gambar 6a dan 6b.

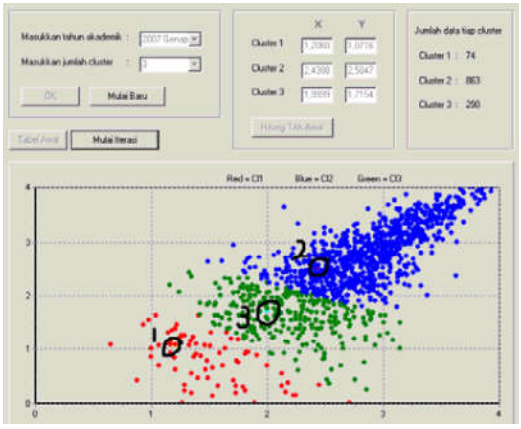

Gambar 6a. Hasil akhir (percobaan 1)

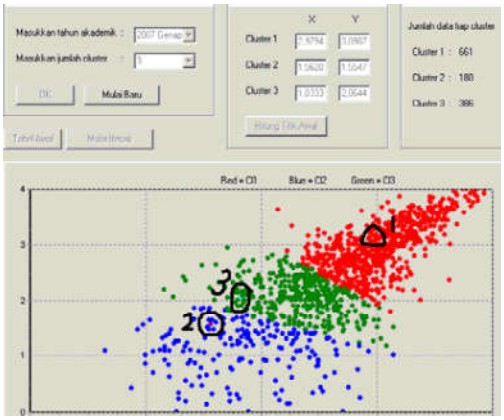

Gambar 6b. Hasil akhir (percobaan 2)

Perbedaan kedua percobaan untuk semester genap 2007/2008 dapat dilihat pada tabel 2. Dari tabel ini dapat dilihat bahwa nilai tengah terbaik ditunjukkan oleh percobaan kedua.

Tabel 2. Perbedaan Percobaan

Hasil K-means	CL1		CL2		CL3	
	IPK	IPS	IPK	IPS	IPK	IPS
Nilai tengah AWAL1	0.6	1.1	2.2	0.7	0.7	1.9
Nilai tengah AKHIR1	1.21	1.07	2.44	2.5	1.9	1.72
Jumlah Data awal 1	27		957		243	
Jumlah Data akhir 1	74		863		290	
Nilai tengah AWAL 2	2.7	1.3	2.7	0.1	3.7	3.8
Nilai tengah AKHIR2	2.97	3.09	1.56	1.55	1.83	2.06
Jumlah Data awal 2	741		38		448	
Jumlah Data akhir 2	661		180		386	

b.3. Data Semester Ganjil 2008/2009

Hasil akhir dari cluster untuk semester genap dengan dua kali percobaan dapat dilihat pada gambar 7a dan 7b.

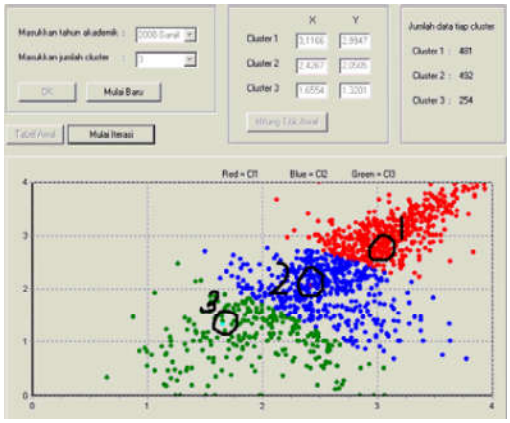

Gambar 7a. Hasil cluster (percobaan 1)

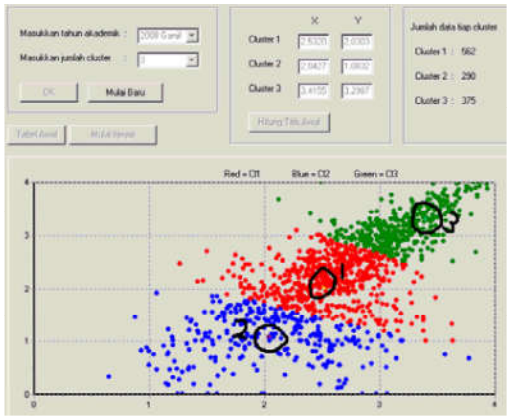

Gambar 7b. Hasil cluster (percobaan 2)

Perbedaan kedua percobaan untuk semester ganjil 2008/2009 dapat dilihat pada tabel 3. Pada tabel tersebut menunjukkan bahwa percobaan pertama memberikan nilai tengah yang lebih baik di-bandingkan percobaan kedua.

Tabel 3. Perbandingan Hasil K-Means Semester Ganjil 2008/2009

Hasil K-means	CL1		CL2		CL3	
	IPK	IPS	IPK	IPS	IPK	IPS
Nilai tengah AWAL1	0.6	1.1	2.2	0.7	0.7	1.9
Nilai tengah AKHIR1	3.11	2.99	2.42	2.05	1.66	1.3
Jumlah Data awal 1	31		1053		143	
Jumlah Data akhir 1	481		492		254	
Nilai tengah AWAL 2	0.6	0.4	0.3	0.3	3.2	0.8
Nilai tengah AKHIR2	2.53	2.03	2.04	1.08	3.42	3.29
Jumlah Data awal 2	103		1		1123	
Jumlah Data akhir 2	562		290		375	

b.4. Data Semester Genap 2008/2009

Hasil akhir dari cluster untuk semester genap dengan dua kali percobaan dapat dilihat pada gambar 8a dan 8b.

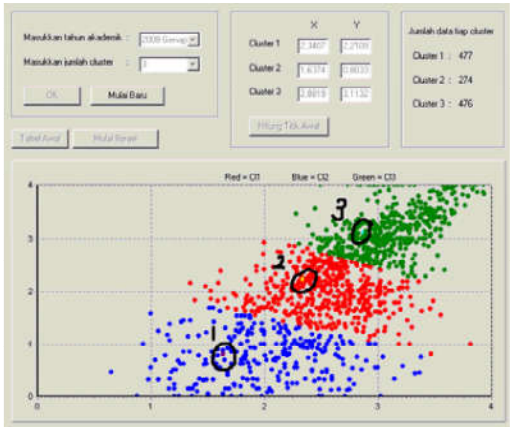

Gambar 8a. Hasil cluster (percobaan 1)

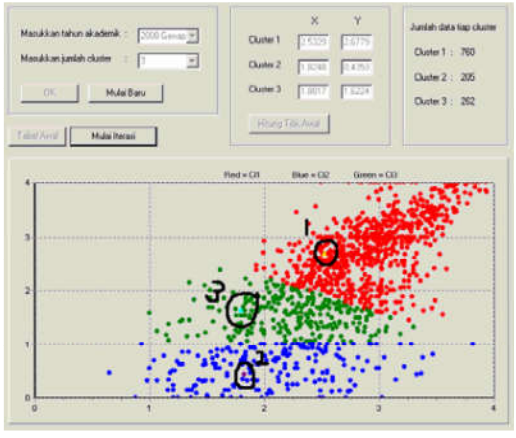

Gambar bb. Hasil cluster (percobaan 2)

Perbedaan kedua percobaan untuk semester genap 2008/2009 dapat dilihat pada tabel 4. Dari tabel 4 terlihat bahwa nilai tengah terbaik ditunjukkan oleh hasil percobaan pertama.

Tabel. 4. Perbandingan Hasil K-Means Semester Genap 2008/2009

Hasil K-means	CL1		CL2		CL3	
	IPK	IPS	IPK	IPS	IPK	IPS
Nilai tengah AWAL1	0.1	2.3	3	0.1	2	2.5
Nilai tengah AKHIR1	2.34	2.2	1.64	0.8	2.88	3.11
Jumlah Data awal 1	10		238		979	
Jumlah Data akhir 1	477		274		476	
Nilai tengah AWAL 2	1.3	2.7	2.8	3.3	3	1.2
Nilai tengah AKHIR2	2.52	2.67	1.83	0.43	1.8	1.62
Jumlah Data awal 2	86		585		556	
Jumlah Data akhir 2	760		205		262	

5. Kesimpulan dan Saran

a. Kesimpulan

Dari penjelasan pada bab-bab sebelumnya maka hasil penelitian ini dapat disimpulkan antara lain:

1. Nilai tengah untuk masing-masing cluster pada tahun akademik 2007/2008 dan 2008/2009 mempunyai hasil yang berbeda
2. Hasil cluster 2007/2008 untuk semester ganjil dan genap mempunyai perbedaan tetapi tidak terlalu signifikan, hal ini dapat dikatakan bahwa proses pembelajaran yang terjadi pada semester ganjil dan genap pada T.A 2007/2008 relatif sama.
3. Hasil cluster 2008/2008 untuk semester ganjil dan genap mempunyai perbedaan yang cukup signifikan, hal ini menunjukkan bahwa proses pembelajarn yang terjadi pada T.A 2008/2009 tersebut tidak sama.
4. Hasil akhir dari clustering menggunakan K-Means sangat dipengaruhi oleh nilai awal titik tengah masing-masing cluster.

b. Saran

Peneliti menyadari bahwa hasil penelitian ini masih jauh dari sempurna sehingga perlu banyak masukkan dari peneliti lain. Hal-hal yang dapat disarankan peneliti agar penelitian ini menjadi sempurna antara lain:

1. Menggunakan aturan baku untuk menentukan banyaknya jumlah cluster awal.
2. Menggunakan perhitungan nilai tengah cluster dengan ukuran pusat yang lain, misalnya rata-rata
3. Banyaknya cluster bisa dipilih secara interaktif

Daftar Pustaka

Andrew W Moore, K-means and Heirarchical Clustering, School of Computer Science, Carniege Melon University, www.cs.cmu.edu/~awm.

Budi Santoso, " Data Mining: Teknik Pemanfaatan Data Untuk Keperluan Bisnis", Graha Ilmu,Yogyakarta,2007.

Jiawei Han,Micheline Kamber, Data Mining : Concepts and Techniques, Morgan Kaufmann Publisher, Microsoft research,2007.

Pedrycz, witold, Knowledge base Clustering, John Wiley&Sons,Inc., 2005.

Pena, J. M., Lozano, J. A. and Larranaga, P. (1999). An empirical comparison of four initialization methods for the k-means algorithm. *Pattern Recognition Lett.,* 20:1027-1040.

Tibshirani, R., Walter, G. and Hastie, T. (2000). Estimating the Number of Clusters in a Dataset using the Gap Statistics, *Technical Report 208*, Department of Statistics, Stanford University, Standford, CA 94305, USA.

http://people.revoledu.com/kardi/tutorial/**kMean**
http://www.autonlab.org/tutorials/kmeans11.pdf