

Prediksi Nilai Mata Kuliah Mahasiswa Menggunakan Algoritma K-Apriori

Lailil Muflikhah*, W. Lisa Yunita, M. Tanzil Furqon

Fakultas Ilmu Komputer, Universitas Brawijaya

Abstract

The main purpose of grade-course prediction is to help students to take elective courses correctly. The most students taking the course is based on the number of students taking the course. A set of student's academic transcript can be analyzed for the patterns of association (association rule) between their subjects and grades. K-Apriori is one of data mining methods to find the patterns of their association rule to purpose for prediction of the other grade-course. The main step of this method is to cluster the data using K-Means and to get the pattern for the subjects and their grade using Apriori algorithm. However, there are missing values due to all offered courses are not taken by each students. Therefore, it is implemented preprocessing data using Wiener Transformation before it is applied to Apriori algorithm to find their pattern. The testing is based on student's academic transcript using minimum support and confidence as 10% with lift ratio > 1 . As a result, the generated rule from low and high GPA are achieved of error rate 8.75% and 8.5%. However, the generated rule from average GPA is achieved of error rate 11%.

Keywords: K-Apriori, Prediction, Association rule, Wiener Transformation, GPA

Abstrak

Tujuan utama dari prediksi nilai mata kuliah adalah membantu mahasiswa mengambil mata kuliah pilihan secara tepat. Kebanyakan mahasiswa mengambil mata kuliah didasarkan pada jumlah mahasiswa mengambil matakuliah. Sekumpulan transkrip mahasiswa dapat dianalisis pola keterkaitan (association rule) antar nilai matakuliah. K-Apriori merupakan metode data mining untuk mencari pola keterkaitan nilai mata kuliah sehingga dapat digunakan memprediksi nilai mata kuliah lain. Tahapan utama metode ini meliputi mengelompokkan data menggunakan metode K-Means dan menemukan pola nilai mata kuliah menggunakan Apriori. Namun terdapat kekosongan nilai karena seluruh mata kuliah yang ditawarkan tidak diambil setiap mahasiswa. Oleh karenanya, dilakukan preprocessing data menggunakan Wiener Transformation sebelum dicari polanya. Pengujian didasarkan tingkat kemampuan akademik mahasiswa dengan minimum support dan confidence sebesar 10% dan lift ratio > 1 . Hasilnya, rule yang dibangkitkan dari IPK di bawah dan di atas rata-rata memiliki tingkat kesalahan sebesar 8.75% dan 8.5%. Sedangkan jika rule dibangkitkan dari IPK rata-rata memiliki kesalahan sebesar 11%.

Kata kunci: K-Apriori, Prediksi, Association Rule, Wiener Transformation, IPK

© 2017 Jurnal SISFO.

Histori Artikel : Disubmit 8 September 2016; Diterima 14 November 2016; Tersedia online 18 Januari 2017

*Corresponding Author

Email address: laililmf@email.com (Lailil Muflikhah)

1. Pendahuluan

Seringkali mahasiswa mengalami kebingungan dalam mengambil mata kuliah pilihan, yang mana tidak didasarkan pada kemampuan prestasi yang dimiliki namun berdasarkan pada jumlah mahasiswa yang mengambil mata kuliah tersebut. Selain itu, minimnya pengetahuan mengenai muatan mata kuliah tersebut menyebabkan mahasiswa kurang tepat dalam menentukan pilihan. Pengambilan mata kuliah pilihan berkaitan dengan mata kuliah prasyarat dan keminatan dari setiap mahasiswa sehingga membutuhkan arahan dari pembimbing akademik. Namun, keterbatasan waktu yang dimiliki dosen pembimbing menjadi pertimbangan untuk membuat suatu sistem yang dapat memprediksi nilai matakuliah yang akan diambil sesuai dengan potensi yang dimiliki oleh mahasiswa tersebut. Untuk membantu mahasiswa dalam permasalahan di atas, diperlukan sistem pendukung keputusan rekomendasi penentuan matakuliah pilihan [1]. Sistem ini dibangun menggunakan data nilai mahasiswa terdahulu untuk memprediksi nilai matakuliah yang terbaik dengan menggunakan metode *Apriori*, namun masih diperlukan pencarian rule yang terbaik dengan memasukkan nilai *minimum support* dan *minimum confidence* secara manual.

K-Apriori merupakan salah satu dari metode dalam data mining untuk mencari keterkaitan antar data berdasarkan karakteristiknya sehingga terbentuk *rule* dengan berbasis pada cluster. Metode ini merupakan pengembangan dan perbaikan dari algoritma Apriori dimana dihasilkan *rule* yang lebih sederhana. Pada metode ini dilakukan penggabungan metode *clustering*, yakni K-Means dan algoritma Apriori melalui tahapan *preprocessing* untuk pembersihan data menggunakan *Wiener Transformation*. Adapun beberapa penelitian terdahulu yang mendukung makalah ini adalah penelitian mengenai “*Web Log Mining using K-Apriori Algorithm*” [2], “*Frequent Itemset Mining of Market Basket Data using K-Apriori Algorithm*” [3] dan “*Aplikasi Association Rule Untuk Menemukan Pola Pada Data Mahasiswa Matematika ITS*” [4].

Sehingga pada penelitian ini digunakan algoritma *K-Apriori* untuk memprediksi nilai matakuliah pilihan keminatan yang akan diambil mahasiswa berdasarkan nilai matakuliah wajib yang telah diambil. Lebih lanjut dilakukan analisis terhadap besarnya tingkat kesesuaian *rule* yang dihasilkan beserta performansi dari metode *K-Apriori*.

2. Tinjauan Pustaka

Beberapa penelitian sebelumnya yang terkait penelitian menggunakan algoritma *K-Apriori* untuk mengolah data menjadi informasi dalam sebuah supermarket untuk mengolah data barang yang berjudul *Frequent Itemset Mining of Basket Data Using K-Apriori Algorithm* [2]. Pada tahapan *preprocessing*, dilakukan pengisian kekosongan nilai dengan metode *Wiener Transformation* terhadap data dalam *Supermarket*. Sistem akan melakukan penghitungan *K-Means* dari nilai *Wiener Transformation* yang telah didapatkan. Setelah didapatkan *cluster* yang sesuai dengan data yang dimasukkan kemudian dilakukan perhitungan *Apriori* untuk mencari pola data barang yang dimasukkan oleh *user*. Sehingga dihasilkan barang yang direkomendasikan sesuai dengan kebiasaan transaksi *customer*.

Adapun penelitian lain yang terkait dengan metode yang sama berjudul *Web Log Mining Using K-Apriori Algorithm* [3]. Penelitian ini ditujukan untuk mencari relevansi data dari *user* dengan data dari *World Wide Web (WWW)*. Selain itu juga terdapat penelitian dengan topik aplikasi *Association Rule Mining* untuk menemukan pola pada data mata kuliah beserta nilai mahasiswa Matematika ITS [4].

2.1 Data Mining

Perolehan informasi berasal dari penggalian data yang berjumlah besar agar bermanfaat disebut dengan data *mining*. Pemanfaatan data *mining* terdiri dari beberapa proses penggabungan untuk mendapatkan sebuah informasi. Sehingga data *mining* dapat dikatakan sebagai bagian dari proses *Knowledge Discovery in Database (KDD)*. Terdapat beberapa tahapan penting data *mining* yaitu [5][6] :

1) *Data Cleaning*

Data yang berasal dari database memiliki banyak noise sehingga dibutuhkan pembersihan data.

2) *Data Integration*

Setelah mendapatkan data relevan dan konsisten, dilakukan penggabungan data.

3) *Data Selection*

Data yang telah digabungkan dipilih yang paling relevan untuk analisis. Proses ini dilakukan penyimpanan menggunakan database, sehingga proses analisis bertumpu pada *data selection*.

4) *Data Transformation*

Kelanjutan dari *data selection*, dimana data yang ada diubah untuk mencari *data pattern* dari sebuah database. Proses ini akan sangat penting untuk mengetahui pola data dari informasi yang akan dicari.

5) *Pattern Evaluation*

Evaluasi dilakukan untuk mengetahui pola yang telah terbentuk telah sesuai dengan *knowledge*. *Pattern evaluation* juga melakukan pengecekan terhadap perhitungan pencarian pola data.

6) *Knowledge Presentation*

Tahap ini merupakan tahap akhir untuk mendapatkan hasil secara visual ditunjukkan ke *user*.

2.2 Association Rule

Association rule dapat diartikan sebagai teknik untuk melakukan pencarian hubungan antar *item* pada sebuah *dataset*. Hubungan yang didapatkan antar *item* berasal dari kombinasi yang terbentuk untuk membuat sebuah *rule*. Pembentukan *association rule* adalah tahap untuk proses akhir data *mining* dalam mengetahui pola data pada sebuah *dataset* [7].

2.2.1 Apriori

Apriori merupakan salah satu teknik data mining dengan mengolah informasi ke dalam bentuk *itemset* berdasarkan jumlah kemunculan data sehingga didapatkan *association rule*. Secara garis besar terdapat dua tahapan yaitu dengan penggabungan (*join*) dan pemangkasan (*prune*) [8]. Dalam algoritma ini diperlukan beberapa kondisi yang dipenuhi yaitu *minimum support*, *confidence lift ratio* dan *benchmark*. *Support* merupakan banyaknya *itemset* yang muncul secara bersamaan dalam sebuah transaksi sehingga disebut juga *support count* sebagaimana dinyatakan dalam persamaan 1 [9]. Sedangkan untuk pembentukan *itemset* dengan 2 kombinasi ditunjukkan pada persamaan 2 [7]:

$$\text{Support}(A) = \frac{\text{Jumlah transaksi yang mengandung } A}{\text{Total transaksi}} \quad (1)$$

$$\begin{aligned} \text{Support}(A, C) &= P(A \cap C) \\ &= \frac{\text{Jumlah transaksi yang mengandung } A \text{ dan } C}{\text{Total transaksi}} \end{aligned} \quad (2)$$

Penentuan nilai *minimum support* digunakan sebagai nilai acuan untuk menentukan batas *minimum itemset* yang menyatakan kelayakan dari *association rule* yang terbentuk. *Itemset* yang tidak layak akan dilakukan pemangkasan, sedangkan *itemset* yang layak akan dilakukan penggabungan [10]. Setelah terbentuk *rule*, dicari nilai *confidence* sebagaimana ditunjukkan dalam persamaan 3 dan 4 [7]. Nilai *minimum confidence* digunakan sebagai parameter untuk menentukan batas terendah tingkat kepercayaan sebuah *rule* terhadap asosiasi yang telah dibentuk [6].

$$\text{Confidence}(A \rightarrow B) = P(B | A) \quad (3)$$

$$P(B|A) = \frac{\text{Jumlah transaksi yang mengandung A dan B}}{\text{Jumlah transaksi yang mengandung A}} \quad (4)$$

Rule yang berasal dari asosiasi *confidence* digunakan sebagai dasar pengambilan keputusan. Dasar pengambilan keputusan ditentukan dengan nilai *lift ratio* > 1 [7]. Kejadian yang ada dalam sebuah *rule* diperoleh secara acak dari *antecedent* dan *consequence*. Nilai *lift ratio* dapat dinyatakan pada persamaan 5 dan 6. *Item* yang memiliki nilai *lift ratio* < 1, dapat dinyatakan tidak ada asosiasi yang kuat antara *antecedent* dengan *consequent* [7].

$$\text{Lift Ratio} = \frac{\text{confidence}}{\text{expected confidence}} \quad (5)$$

$$\text{Lift Ratio} = \frac{\Pr(A|C)}{\Pr(C)} \quad (6)$$

2.3 K-Means

Dalam data *mining*, *clustering* adalah salah satu teknik yang digunakan untuk mengelompokkan data dalam sebuah *data set*. Metode ini, mengelompokkan data sesuai dengan jumlah *cluster* berdasarkan nilai rata-rata jarak terdekat sehingga dihasilkan pengelompokan dengan tingkat kemiripan tertinggi [11]. Langkah-langkah *clustering K-Means* dengan penghitungan kedekatan jarak dari seluruh pasangan data serta menentukan ketepatan data dalam *clustering* yang telah terbentuk berdasarkan kedekatan jarak yang salah satunya menggunakan *Manhattan Distance* sebagaimana dalam persamaan 7 [12]:

$$d(x, y) = \sum ||x_i - y_i|| \quad (7)$$

dimana $x = \text{dataset}$ dari matriks baris $x_1, x_2, \dots, \dots, x_m$ dan $y = \text{dataset}$ dari matriks kolom $y_1, y_2, \dots, \dots, y_m$.

2.4 K-Apriori

Algoritma *K-Apriori* memiliki dua algoritma utama yang digunakan yaitu *K-Means* dan *Apriori*. Namun sebelum melakukan perhitungan menggunakan kedua algoritma tersebut harus melakukan tahapan *preprocessing data* dengan menggunakan *Wiener Transformation*. Kemudian dilakukan penghitungan dengan algoritma *K-Means* untuk mencari data dengan tingkat kemiripan tertinggi. Setelah mendapatkan kemiripan, dilakukan proses pencarian *rule* menggunakan algoritma *Apriori*.

Tahap *preprocessing* pada *K-Apriori* dilakukan dengan memasukkan data pada matriks p (baris) \times q (kolom). Pendekatan perhitungan *Wiener Transformation* dibantu dengan perhitungan *mean* (μ) dan varian (σ^2). *Mean* dan varian dihitung dari input X , yaitu data mentah yang dibersihkan. Perhitungan *mean* dan varian sebagaimana dalam persamaan 8 dan 9 yang telah ada *mean* (μ) [2]:

$$\mu = \frac{1}{pq} \sum_{n_1 n_2 \in n} X(n_1, n_2) \quad (8)$$

dimana: μ = rata-rata nilai per kolom *input*; p = baris *input*; q = kolom *input*; n_1 = data ke-1; n = data ke- n ; X = *input* matriks 2 dimensi.

Sedangkan persamaan 9 merupakan perhitungan varian (σ^2) [2]:

$$\sigma^2 = \frac{1}{pq} \sum_{n_1 n_2 \in n} (X^2(n_1, n_2) - \mu) \quad (9)$$

dimana: σ^2 = varian; p = baris *input*; q = kolom *input*; n_1 = data ke-1; n = data ke- n ; X^2 = kuadrat *input* matriks dua dimensi; μ = rata-rata nilai per kolom *input*.

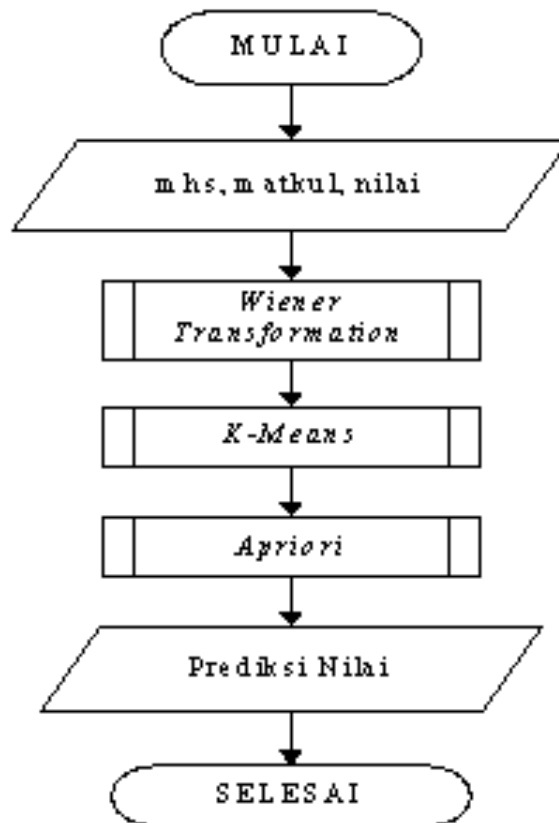
Nilai varian pada persamaan 10 merupakan perhitungan dari matriks X terhadap nilai p (baris) dan q (kolom) kemudian dikurangi matriks *mean* $1 \times q$ (kolom). Lebih lanjut dituliskan pada persamaan 10 untuk mendapatkan $Y(n_1, n_2)$ sebagai luaran dari metode *Wiener Transformation* [2] :

$$Y(n_1, n_2) = \mu + \frac{\sigma^2 - v^2}{\sigma^2} (X(n_1, n_2) - \mu) \quad (10)$$

dimana: σ^2 = varian; v^2 = rata-rata nilai hasil varian; n_1 = data ke-1; n = data ke- n ; X^2 = kuadrat *input* matriks dua dimensi; μ = rata-rata nilai per kolom *input*; Y = *output* matriks 2 dimensi. Sedangkan untuk mendapatkan nilai dari v^2 didasarkan pada persamaan 11 [2]:

$$v^2 = \frac{\sigma^2}{\sum \sigma^2} \quad (11)$$

3. Metodologi



Gambar 1 Gambaran Umum Prediksi Nilai Matakuliah Menggunakan *K-Apriori*

Metode yang digunakan dalam penelitian ini adalah *K-Apriori* sebagaimana ditunjukkan dalam gambaran umum sistem pada Gambar 1. Beberapa parameter masukan meliputi nama dan NIM mahasiswa, matakuliah beserta nilainya, *minimum support*, dan *minimum confidence*. Sebagai langkah awal dilakukan *preprocessing* menggunakan *Wiener Transformation* untuk menghilangkan *noise* (kekosongan nilai) pada

data. Nilai Y sebagai luaran dari *Wiener Transformation* digunakan untuk proses *clustering* yang mana digunakan *K-means* terhadap empat bidang minat. *Data training* yang digunakan sebagai data input diproses menggunakan *association rule* untuk dicari *frequent itemset* tertinggi. Pencarian *frequent itemset* dilakukan dengan menghitung *support count* pada setiap *rule* yang terbentuk. Sedangkan nilai *confidence* digunakan untuk pencarian *rule* yang memenuhi nilai kepercayaan dari *rule* yang terbentuk. Nilai *lift ratio* digunakan untuk mengetahui kekuatan *rule* terhadap data yang digunakan. *Rule* yang telah terbentuk dilakukan pencocokan terhadap input data sehingga prediksi nilai mata kuliah diperoleh berdasarkan *rule* yang terbentuk dengan mempertimbangkan nilai yang diinputkan.

3.1 Preprocessing Data

Adapun tahapan *preprocessing* dalam rangka penghilangan *missing value* dengan *Wiener Transformation* adalah sebagai berikut :

- 1) Dilakukan penghitungan nilai *mean* (μ) dari data krs mahasiswa ke dalam matriks $1 \times q$ (Id mahasiswa) dari data konversi nilai ke dalam bentuk angka.
- 2) Dilakukan penghitungan nilai varian (σ^2) dari data ke dalam matriks $1 \times q$ (Id mahasiswa).
- 3) Dilakukan penghitungan rata-rata varian (σ^2) ke dalam matriks skalar.
- 4) $Y(n_1, n_2)$ merupakan hasil perhitungan *mean* dan varian yang telah didapatkan dalam bentuk matriks p (mata kuliah) $\times q$ (Id mahasiswa)

3.2 Proses Clustering dengan K-means

Setelah *preprocessing data*, dilakukan *clustering* terhadap hasil dari *Wiener Transformation*. Prediksi nilai mata kuliah pilihan berdasarkan empat keminatan sehingga menjadikan adanya empat *cluster*. Adapun empat keminatan yang ada di Fakultas Ilmu Komputer pada Program studi Informatika Universitas Brawijaya meliputi: 1. Rekayasa Perangkat Lunak; 2. Pengembang Sistem Cerdas; 3. Perancangan dan Pengembangan Game; 4. Perekrayan Jaringan Komputer (*Computer Network Engineer*). Lebih lanjut penghitungan *K-means* untuk melakukan *clustering data* berdasarkan tingkat kemiripannya dengan mengacu pada persamaan 2 sebagaimana berikut:

- 1) Pengambilan data dari *wiener transformation*
- 2) *Clustering* terhadap data *wiener transformation* secara random
- 3) Perhitungan jumlah nilai data sesuai *cluster* yang terbentuk.
- 4) Penghitungan nilai *centroid* setiap data menggunakan penghitungan *Manhattan Distance*.
- 5) Pencarian nilai minimum dari *cluster* $||x_i - z_j||$.
- 6) Penentuan *cluster* baru.
- 7) Perbandingan hasil penjumlahan $||x_i - z_j \leq x_i - z_t||$. Jika $j \neq t$ maka kembali ke langkah 4 hingga dicapai $j=t$.

3.3 Proses Association Rule Apriori

Setelah didapatkan data transaksi, maka dilakukan pencarian pola aturan menggunakan *Apriori*. Pembentukan *itemset* dilakukan dengan menggabungkan mata kuliah dengan nilai yang ada pada setiap transaksi yang ada. Sedangkan nomor transaksi menggunakan nomor mahasiswa yang masuk dalam *cluster* yang sama dengan data *input*.

Proses *Apriori* dilakukan dengan melakukan pembuatan *large itemset* yang akan digunakan untuk mendapatkan *rule*. *Rule* yang didapat nantinya merupakan hasil dari kombinasi *itemset* yang akan dibandingkan dengan kesesuaian data *item data input*. Pembentukan *rule* akhir berdasarkan nilai minimum

support dan minimum *confidence* yang telah diinputkan oleh *user*. Pencarian pola aturan menggunakan *Apriori* sebagai berikut:

- 1) Dilakukan pengambilan data dari konversi, *wiener transformation*, *k-means* dan data transaksi.
- 2) Pembentukan *Large-1 itemset*, jika terdapat kemunculan *Large-1 itemset*, maka dilanjutkan ke Langkah 3. Jika *itemset* tidak ditemukan, maka akan dilakukan pemangkasan (*prune*).
- 3) Pembandingan *frequent itemset* dengan nilai minimum *support* pada *Large-1 itemset*.
- 4) Pembandingan *frequent itemset* dengan nilai minimum *confidence* pada *Large-1 itemset*.
- 5) Penghitungan nilai *lift ratio* untuk mengetahui kekuatan *rule*. Jika *lift ratio* kurang dari 1 maka akan dilakukan pemangkasan (*prune*).
- 6) Penyimpanan *database rule* yang memiliki kesamaan dengan *input* data.
- 7) Pembentukan *Large-n+1 itemset* dan diulangi langkah 2-6 dengan ketentuan *Large-n+1 itemset* setiap *rule* yang baru terbentuk.

Data *itemset* yang memenuhi minimum *support* dipilih untuk pembentukan *rule*. Nilai minimum *confidence* digunakan untuk mengetahui data yang memiliki kekuatan terhadap *rule* tertinggi. Penghitungan *lift ratio* dilakukan untuk menguji lemah atau tidaknya sebuah *rule* yang telah terseleksi dalam tahap *confidence*. Jika sebuah *rule* memiliki nilai *lift ratio* kurang dari 1, maka *rule* tersebut kurang baik untuk digunakan sebagai pengambilan keputusan. Pengambilan keputusan hanya didasarkan dari nilai *lift ratio* ≥ 1 yang digunakan untuk melakukan pengecekan terhadap *input* data. Jika *rule* yang terbentuk memiliki kesamaan dengan *input* data, maka *rule* akan disimpan dalam *database*. Penyimpanan *rule* akan digunakan sebagai pertimbangan untuk melakukan prediksi nilai mata kuliah.

3.4 Contoh Permasalahan

Misalkan diberikan data set dari KRS mahasiswa PTIIK angkatan 2008-2011 yang telah lulus. Pada data *training* mencakup keseluruhan nilai baik mata kuliah wajib maupun pilihan. Namun pada data uji hanya digunakan data mata kuliah wajib sebagaimana ditunjukkan pada Tabel 1.

Tabel 1. Data set mahasiswa beserta nilai matakuliah

Kel MatKul	Mata kuliah	Nilai										
		Nur	Hadi	Dwi	Putra	Mila	Widi	Said	Anisa	Dimas	Zainuri	Nita
S	DatMin	B+	-	A	A	sB+	B	A	D	A	C+	C+
i	PCD	B	-	B+	A	A	A	B+	-	A	-	B+
s	SisPak	B+	-	A	A	A	A	B+	-	A	-	-
C	SPK	A	-	A	A	A	A	A	A	A	-	-
e	STKI	A	-	-	-	-	B+	-	-	B	-	-
r	LogFuz	B	-	A	-	B	-	B+	C+	B+	-	A
d	PemTeks	-	-	-	-	-	-	-	-	-	-	-
a	JST	C+	-	B+	B+	B+	B	A	-	B	-	-
s	Alev	B	-	A	A	A	B	B	-	B+	-	-
	MPPL	D+	-	-	-	B+	-	B	A	-	B	-
R	PPP	-	-	-	-	-	-	-	-	-	-	-
P	PBPU	-	-	-	-	-	-	-	-	-	-	-
L	PAPB	B+	A	A	-	-	-	-	-	-	A	-

Kel MatKul	Mata kuliah	Nilai										
		Nur	Hadi	Dwi	Putra	Mila	Widi	Said	Anisa	Dimas	Zainuri	Nita
G a m e	PPL	-	B	-	-	-	-	C+	-	-	-	-
	ABD	C+	-	B+	C+	-	-	-	-	B+	B	C+
	BDT	-	C	-	-	-	-	-	-	B	B	-
	ERP	B+	-	B+	A	A	B	A	-	B+	-	-
	GamePro	-	-	A	A	A	-	-	-	-	-	-
	MR	-	A	A	A	A	-	-	A	-	-	-
	ProgGame	-	-	-	-	-	-	-	-	-	-	-
	Penggame	-	-	-	-	-	-	-	-	C+	-	-
	PerGame	-	B	-	-	-	-	-	-	-	B+	-
	GameAI	-	-	-	-	-	B+	-	-	-	-	-
J a r K o m	ProgGraf3D	-	-	-	-	-	-	-	-	-	-	-
	PK3d	-	-	-	-	-	-	-	-	-	-	-
	PMGame	-	-	-	-	-	-	-	-	-	-	-
	AJT	-	A	-	A	-	-	A	-	-	A	-
	Jarmul	-	B	-	-	-	-	-	-	-	B	-
	JarLan	-	A	-	-	-	-	-	-	-	B	-
	PAJ	-	B+	-	-	-	-	-	-	-	-	-
	Sister	-	A	-	-	-	-	-	B	-	A	-
	ProgJar	-	-	-	-	-	-	-	-	-	A	-
	AdSer	-	A	-	-	-	-	-	-	-	A	-
W a j i b	Jarnil	-	A	-	-	-	-	-	-	-	-	-
	BasDat	B+	A	A	B	B	B+	B+	C+	B+	A	B
	KC	B+	C+	A	B	B+	B	B	C+	B+	B	B
	MatKom	A	B	A	A	A	B+	A	B	A	B+	B
	MatKomLan	B	B+	A	B	B+	B	A	D+	C+	C+	B
	PBO	B+	B	B	B+	B	B	C+	B	A	B	B+
	GrafKom	B+	B	B+	B+	B+	B	A	B	B+	C+	B
	IMK	B	B+	B	A	A	B+	B+	B	B	B+	B
	Jarkom	B	B+	C+	B+	B	B	A	C+	B+	B	C+
	RPL	B+	B+	B+	A	B+	C+	B	B+	B+	B+	B
	ASD	C+	C+	B	B	B	C+	B	C	B	B+	C+

3.4.1 Preprocessing Data

Pada Tabel 1, terlihat nilai dalam bentuk huruf sehingga dilakukan konversi ke dalam bentuk angka (A=4; B+=3.5; B=3; C+=2.5; C=2; D=1; E=0). Namun terdapat kekosongan nilai pada beberapa mata kuliah

pilihan maka diperlukan transformasi nilai mahasiswa secara keseluruhan dengan menggunakan metode *Wiener Transformation* sebagaimana ditunjukkan dalam contoh berikut:

1) Menghitung *Mean*

Misalkan dilakukan penghitungan *mean* dilakukan terhadap 11 data, 10 data merupakan data *training* dan 1 data *testing*. Perhitungan *mean* dilakukan pada matriks X_i (vector X (baris) terhadap kolom).

$$\mu = \frac{1}{11} * (\sum V[3.5_1 + 0_2 + 4_3 + \dots + 0_{11}]) = 2.68$$

Tabel 2. Menghitung *mean*

Mata kuliah	Nur	Hadi	Dwi	Putra	Mila	Widi	Said	Anisa	Dimas	Zainuri	Nita	μ
DatMin	3.5	0	4	4	3.5	3	4	1	4	2.5	0	2.68

2) Menghitung Varian

Nilai *mean* digunakan untuk mencari nilai varian. Dimana varian membutuhkan nilai kuadrat X_i dan nilai μ_i pada setiap kolom. Penghitungan varian dilakukan terhadap 11 data, 10 data merupakan data *training* dan 1 data *testing*. $\sigma^2 = \frac{1}{11} * ((\sum V[(3.5)^2 - 2.68_1]) + \dots + ((2.5)^2 - 2.77_{26})) = 6.84$

Tabel 3. Menghitung Varian

Mata kuliah	Nur	Hadi	Dwi	Putra	Mila	Widi	Said	Anisa	Dimas	Zainuri	Nita	σ^2
DatMin	9.57	-2.68	13.32	13.32	9.57	6.32	13.32	-1.68	13.32	3.57	-2.68	6.84

3) Mencari Nilai $Y(n_1, n_2)$

Nilai $Y(n_1, n_2)$ diperoleh dari rata-rata varian pada setiap matriks skalar per mata kuliah. Hasil seluruh varian dijumlahkan dan dibagi dengan jumlah kolom sebesar jumlah matakuliah yakni 44.

$$v^2 = \frac{1}{44} * (\sum V[6.84_1 + 6.50_2 + 7.05_3 + \dots + 5.07_{44}]) = 3.74$$

Penghitungan $Y(n_1, n_2)$ didapatkan nilai $1 \times q$ di setiap matriks X_i terhadap jumlah baris (n).

$$Y(n_1, n_2) = 2.68_1 + \frac{6.84_1 - 3.74_1}{6.84_1} * (3.5_{1,1} - 2.68_1) = 3.05$$

Tabel 4. Nilai Y

Mata kuliah	Nur	Hadi	Dwi	Putra	Mila	Widi	Said	Anisa	Dimas	Zainuri	Nita
DatMin	3.05	1.47	3.28	3.28	3.05	2.83	3.28	1.92	3.28	2.60	1.47

Sehingga hasil transformasi secara keseluruhan ditunjukkan pada Tabel 5.

Tabel 5. Nilai matakuliah bidang minat Sistem Cerdas menggunakan *Wiener Transformation*

No	Nama	Sistem Cerdas								
		DatMin	PCD	SisPak	SPK	STKI	LogFuz	PemTeks	JST	Alev
1	Nur	3.05	2.63	2.94	3.53	0.69	1.88	0.00	2.19	2.49
2	Hadi	1.47	1.36	1.30	1.25	1.47	1.61	0.00	1.59	1.46

No	Nama	Sistem Cerdas								
		DatMin	PCD	SisPak	SPK	STKI	LogFuz	PemTeks	JST	Alev
3	Dwi	3.28	2.85	3.18	3.53	1.47	1.97	0.00	2.43	2.84
4	Putra	3.28	3.06	3.18	3.53	1.47	1.61	0.00	2.43	2.84
5	Mila	3.05	3.06	3.18	3.53	1.47	1.88	0.00	2.43	2.84
6	Widi	2.83	3.06	3.18	3.53	0.42	1.61	0.00	2.31	2.49
7	Said	3.28	2.85	2.94	3.53	1.47	1.93	0.00	2.54	2.49
8	Anisa	1.92	1.36	1.30	3.53	1.47	1.84	0.00	1.59	1.46
9	Dimas	3.28	3.06	3.18	3.53	0.15	1.93	0.00	2.31	2.66
10	Zainuri	2.60	1.36	1.30	1.25	1.47	1.61	0.00	1.59	1.46
11	Nita	1.47	1.36	1.30	1.25	1.47	1.61	0.00	1.59	1.46

3.4.2 Proses *Clustering* dengan K-Means

Kemudian dilakukan pengelompokan berdasarkan empat bidang keminatan menggunakan metode *K-Mean clustering* dan sebagai ilustrasi ditunjukkan dalam Tabel 6.

Tabel 6. *Cluster Data Informasi Akademik Mahasiswa*

No	Nama	Cluster Data			
		K1	K2	K3	K4
1	Nur	*			
2	Hadi				*
3	Dwi	*			
4	Putra		*		
5	Mila			*	
6	Widi	*			
7	Said		*		
8	Anisa			*	
9	Dimas		*		
10	Zainuri				*
11	Nita	*			

3.4.3 Proses *Association Rule* menggunakan algoritma *Apriori*

Selanjutnya dilakukan pembentukn *rule* menggunakan algoritma *Apriori*. Adapun data yang digunakan memiliki kesamaan cluster dengan data uji misalkan data ke-11 untuk dilakukan pencarian pola prediksi. Pada awalnya terbentuk *Large-1* itemset dengan *threshold* misalkan dengan memberikan minimum support=30% dan minimum *confidence* =50%.

DATMIN_A \rightarrow 3, DATMIN_B+ \rightarrow 2, PCD_A \rightarrow 2, PCD_B+ \rightarrow 2, SISPAK_A \rightarrow 3, SISPAK_B+ \rightarrow 2, SPK_A \rightarrow 6, LOGFUZ_B \rightarrow 2, JST_B+ \rightarrow 3, ALEV_B \rightarrow 2, ABD_C+ \rightarrow 2, ERP_A \rightarrow 3, ERP_B+ \rightarrow 2, GAMEPRO_A \rightarrow 3, MR_A \rightarrow 4, AJT_A \rightarrow 2, BASDAT_B+ \rightarrow 2, BASDAT_B \rightarrow 2, KC_B+ \rightarrow 2, KC_B \rightarrow 2, MATKOM_A \rightarrow 5, MATKOMLAN_A \rightarrow 2, MATKOMLAN_B \rightarrow 2, PBO_B+ \rightarrow 2, PBO_B \rightarrow 3, GRAFKOM_B+ \rightarrow 4, IMK_A \rightarrow 2, IMK_B \rightarrow 3, JARKOM_B \rightarrow 2, JARKOM_C+ \rightarrow 3, RPL_B+ \rightarrow 4 dan ASD_B \rightarrow 4.

Gambar 4 Rule dari Pembentukan *Large-1* itemset

Pada Gambar 4 terlihat sejumlah *itemset* yang memenuhi minimum *support*, kemudian dilakukan kombinasi 2 *itemset*. Pada penggabungan *itemset* yaitu DATMIN_B+ dan SPK_A dengan nilai *support* $\{ \text{DATMIN_B+} \rightarrow \text{SPK_A} \} = \frac{3}{6} \times 100\% = 50\%$, sedangkan nilai *confidence* sebesar $\frac{3}{3} \times 100\% = 100\%$; *Itemset* yang memenuhi *threshold minimum support* dan *minimum confidence* dapat dinyatakan sebagai *rule*. Untuk mendapatkan nilai *lift ratio*, dilakukan penghitungan *benchmark confidence* untuk menentukan nilai probabilitas terhadap *rule* yang terbentuk. Adapun *benchmark confidence* $\{ \text{DATMIN_B+} \rightarrow \text{SPK_A} \} = \frac{6}{6} = 1.00$ dan nilai *lift ratio* $= \frac{\frac{3}{6}}{\frac{6}{6}} = \frac{1}{1} = 1.00$. Sehingga secara keseluruhan dari pembentukan *Large-2 itemset* dihasilkan sebagaimana Gambar 5 dan *rule* yang terpilih dapat dituliskan hasil prediksi dari matakuliah beserta nilainya seperti pada Tabel 7.

PCD_B+ \rightarrow SPK_A; ABD_C+ \rightarrow SISPAK_A; DATMIN_B \rightarrow SISPAK_A; ABD_C+ \rightarrow SPK_A; BASDAT_B \rightarrow SPK_A; KC_B \rightarrow SPK_A; MATKOMLAN_B \rightarrow SPK_A; PBO_B+ \rightarrow SPK_A; IMK_B \rightarrow SPK_A; JARKOM_C+ \rightarrow SPK_A; BASDAT_B \rightarrow JST_B+; BASDAT_B \rightarrow ALEV_A; BASDAT_B \rightarrow ERP_A; BASDAT_B \rightarrow GAMEPRO_A; BASDAT_B \rightarrow MR_A; KC_B \rightarrow AJT_A.

Gambar 5 Rule yang terpilih dari pembentukan *Large-2* itemset

Tabel 7. Mata Kuliah beserta Prediksi Nilai

Matkul	Nilai
SPK	A
SISPAK	A
JST	B+
ALEV	A
ERP	A
GAMEPRO	A
MR	A
AJT	A

4. Hasil dan Pembahasan

Skenario pengujian dilakukan untuk mengetahui pengaruh dari *rule* yang terbentuk dari sekelompok data berdasarkan tingkat kemampuan mahasiswa yakni tingkat kemampuan rata-rata, tingkat kemampuan diatas rata-rata dan tingkat kemampuan dibawah rata-rata. Adapun data masukan berupa data mahasiswa dengan mata kuliah wajib beserta nilainya dengan nilai minimum *support*=10% dan minimum *confidence*=10% dengan *lift ratio*>1 yang digunakan dalam menentukan prediksi mata kuliah pilihan beserta nilainya berdasarkan tingkat kemampuan akademik yang dimiliki.

4.1 Tingkat Kemampuan Mahasiswa Rata-Rata

Hasil prediksi dari *rule* memiliki beberapa bagian, yaitu jumlah nilai *error* dengan 7 data yang masuk pada *cluster* yang sama dengan *input* data *user*. Kondisi yang digunakan dalam melakukan pengujian yaitu pada *minsup* dan *mincof* sebesar 10%. Tabel 8 adalah hasil prediksi yang diberikan sistem dibandingkan dengan data riil.

Tabel 8. Prediksi Mata kuliah beserta Nilai pada Tingkat Kemampuan Mahasiswa Rata-Rata

No	Data Riil	Data Prediksi	Selisih (Error)
1	Arsitektur Jaringan Terkini=>-	Arsitektur Jaringan Terkini=>B	-
2	Jaringan Multimedia=>-	Jaringan Multimedia=>A	-
3	Perancangan dan Analisa Jaringan Komputer=>-	Perancangan dan Analisa Jaringan Komputer=>B	-
4	Sistem Terdistribusi=>-	Sistem Terdistribusi=>B	-
5	Jaringan Nirkabel=>-	Jaringan Nirkabel=>A	-
6	Pengembangan Aplikasi Perangkat Bergerak=>B+	Pengembangan Aplikasi Perangkat Bergerak=>B	3.5-3 =0.5
7	Administrasi Basis Data=>C+	Administrasi Basis Data=>A	2.5-4 =1.5
8	Basis Data Terdistribusi=>-	Basis Data Terdistribusi=>B+	-
9	ERP=>A	ERP=>A	0-0 =0
10	Perancangan Sumberdaya Perusahaan(ERP)=>A	Perancangan Sumberdaya Perusahaan=>C	4-2 =2
11	Game AI=>-	Game AI=>B+	-
12	Logika Fuzzy=>A	Logika Fuzzy=>B+	4-3.5 =0.5
13	Administrasi Basis Data=>C+	Administrasi Basis Data=>B	2.5-3 =0.5
14	Perencanaan Sumberdaya Perusahaan(ERP)=>A	Perencanaan Sumberdaya Perusahaan=>B	4-3 =1
15	Pola-Pola Perancangan=>-	Pola-Pola Perancangan=>B	-
16	Pengembangan Aplikasi Perangkat Bergerak=>B+	Pengembangan Aplikasi Perangkat Bergerak=>A	3.5-4 =0.5
17	Administrasi Basis Data=>C+	Administrasi Basis Data=>B+	2.5-3.5 =1

Dari hasil prediksi, didapatkan selisih nilai *error* terhadap data yaitu, $\frac{0.5+1.5+2+0.5+0.5+1+0.5+1}{4} = \frac{7}{4} = 1.75$.
 $\frac{0.44}{4} \times 100\% = 11\%$, dimana nilai seluruh selisih dijumlahkan dan dibagi rentang nilai tertinggi yaitu 4. Nilai 4 digunakan karena rentang nilai tertinggi dimiliki oleh nilai A.

4.2 Tingkat Kemampuan Mahasiswa diatas Rata-rata

Hasil prediksi dari *rule* memiliki beberapa bagian yaitu jumlah nilai *error* dengan 5 data yang masuk pada *cluster* yang sama dengan *user*. Kondisi yang digunakan untuk melakukan pengujian yaitu pada *minsup* dan *mincof* sebesar 10% yang ditunjukkan pada Tabel 9.

Dari hasil pemberian prediksi mata kuliah beserta nilainya, didapatkan selisih nilai *error* terhadap data

yaitu, $\frac{0.5+0.5+1+0.5+1+1+1+1.5+0.5+0.5+0.5}{4} = \frac{19}{4} = \frac{0.34}{4} \times 100\% = 8.5\%$, dimana nilai seluruh selisih dijumlahkan dan dibagi rentang nilai tertinggi yaitu 4. Nilai 4 digunakan karena rentang nilai tertinggi dimiliki oleh nilai A.

Tabel 9. Prediksi Mata kuliah beserta Nilai pada Tingkat Kemampuan Mahasiswa Diatas rata-rata

No	Data Riil	Data Prediksi	Selisih (Error)
1	Jaringan Multimedia=>-	Jaringan Multimedia=>A	-
2	Pemrograman Jaringan=>-	Pemrograman Jaringan=>B	-
3	Jaringan Nirkabel=>-	Jaringan Nirkabel=>A	-
4	Sistem pakar=>B+	Sistem pakar=>B	$ 3.5-3 =0.5$
5	Sistem Temu Kembali Informasi=>B+	Sistem Temu Kembali Informasi=>A	$ 3.5-4 =0.5$
6	Sistem Temu Kembali Informasi=>B+	Sistem Temu Kembali Informasi=>B+	$ 0-0 =0$
7	Logika Fuzzy=>A	Logika Fuzzy=>A	$ 0-0 =0$
8	Perencanaan Sumberdaya Perusahaan(ERP)=>A	Perencanaan Sumberdaya Perusahaan(ERP)=>A	$ 0-0 =0$
9	Logika Fuzzy=>A	Logika Fuzzy=>B	$ 4-3 =1$
10	Pengembangan Aplikasi Perangkat Bergerak=>B+	Pengembangan Aplikasi Perangkat Bergerak=>B	$ 3.5-3 =0.5$
11	Administrasi Basis Data=>C+	Administrasi Basis Data=>B+	$ 2.5-3.5 =1$
12	Basis Data Terdistribusi=>-	Basis Data Terdistribusi=>B+	-
13	Perencanaan Sumberdaya Perusahaan(ERP)=>A	Perencanaan Sumberdaya Perusahaan(ERP)=>B	$ 4-3 =1$
14	Sistem Pakar=>B+	Sistem Pakar=>B+	$ 0-0 =0$
15	Administrasi Basis Data=>C+	Administrasi Basis Data=>A	$ 2.5-4 =1.5$
16	Logika Fuzzy=>A	Logika Fuzzy=>B+	$ 4-3.5 =0.5$
17	Basis Data Terdistribusi=>-	Basis Data Terdistribusi=>A	-
18	Perencanaan Sumberdaya Perusahaan(ERP)=>A	Perencanaan Sumberdaya Perusahaan(ERP)=>B+	$ 4-3.5 =0.5$
19	Administrasi Basis Data=>C+	Administrasi Basis Data=>B	$ 2.5-3 =0.5$

4.3 Tingkat Kemampuan Mahasiswa dibawah Rata-rata

Hasil prediksi dari *rule* memiliki beberapa bagian, yaitu jumlah nilai *error* dengan 5 data yang masuk pada *cluster* yang sama dengan *user*. Kondisi yang digunakan untuk melakukan pengujian yaitu pada *minsup* dan *mincof* sebesar 10%, yang ditunjukkan pada Tabel 10.

Tabel 10. Prediksi Mata kuliah beserta Nilai pada Tingkat Kemampuan Mahasiswa Dibawah rata-rata

No	Data Riil	Data Prediksi	Selisih (Error)
1	Arsitektur Jaringan Terkini=>-	Arsitektur Jaringan Terkini=>B	-
2	Jaringan Multimedia=>-	Jaringan Multimedia=>B	-
3	Jaringan Komputer Lanjut=>-	Jaringan Komputer Lanjut=>C+	-

No	Data Riil	Data Prediksi	Selisih (<i>Error</i>)
4	Sistem Terdistribusi=>-	Sistem Terdistribusi=>A	-
5	Pemrograman Jaringan=>-	Pemrograman Jaringan=>B+	-
6	Pengolahan Citra Digital=>B+	Pengolahan Citra Digital=>B+	0-0 =0
7	Logika Fuzzy=>A	Logika Fuzzy=>B	4-3 =1
8	Logika Fuzzy=>A	Logika Fuzzy=>C+	4-2.5 =1.5
9	Managemen Proyek Perangkat Lunak=>C+	Managemen Proyek Perangkat Lunak=>B	2.5-3 =0.5
10	Perancangan dan Analisa Jarkom=>-	Perancangan dan Analisa Jarkom=>B	-
11	Jaringan Nirkabel=>-	Jaringan Nirkabel=>B	-
12	Pengembangan Apikasi Perangkat Bergerak=>B+	Pengembangan Apikasi Perangkat Bergerak=>A	3.5-4 =0.5
13	Administrasi Basis Data=>C+	Administrasi Basis Data=>D	2.5-2 =0.5
14	Pemrograman Game=>-	Pemrograman Game=>B	-
15	Administrasi Basis Data=>C+	Administrasi Basis Data=>B+	2.5-3.5 =1
16	Perencanaan Sumberdaya Perusahaan(ERP)=>A	Perencanaan Sumbersaya Perusahaan=>B	4-3 =1
17	Perancangan dan Analisa Jarkom=>-	Perancangan dan Analisa Jarkom=>B+	-
18	Sistem Terdistribusi=>-	Sistem Terdistribusi=>C+	-
19	Jaringan Nirkabel=>-	Jaringan Nirkabel=>B+	-
20	Administrasi Basis Data=>C+	Administrasi Basis Data=>C+	0-0 =0
21	Perencanaan Sumberdaya Perusahaan=>A	Perencanaan Sumberdaya Perusahaan=>C	4-2 =2
22	Perancangan dan Analisa Jarkom=>-	Perancangan dan Analisa Jarkom=>C+	-
23	Jaringan Nirkabel=>-	Jaringan Nirkabel=>A	-

Dari hasil prediksi mata kuliah beserta nilainya, didapatkan selisih nilai *error* terhadap data yaitu, $\frac{1+1.5+0.5+0.5+0.5+1+1+2}{23} = \frac{0.35}{4} = 8.75\%$, dimana nilai seluruh selisih dijumlahkan dan dibagi rentang nilai tertinggi yaitu 4. Nilai 4 digunakan karena rentang nilai tertinggi dimiliki oleh nilai A.

Sehingga untuk mengetahui manfaat *rule* atau ketepatan dalam prediksi mata kuliah beserta nilainya maka diukur tingkat kesalahan dari hasil pengujian tersebut sebagaimana ditunjukkan dalam Tabel 11.

Tabel 11. Perbandingan Tingkat Kesalahan berdasarkan Kemampuan Prestasi Mahasiswa

No	Jenis Pengujian	Error rate
1	Kemampuan IP Rata-Rata	11%
2	Kemampuan IP Tinggi	8.75%
3	Kemampuan IP Rendah	8.5%

Untuk mengetahui performansi dari metode yang digunakan dalam penelitian ini dilakukan penghitungan waktu komputasi dari algoritma *K-Apriori* yang terdiri dari tiga metode: *preprocessing* (*Wiener Transformation*), *Clustering* (*K-Means*) dan pencarian *rule* (*Apriori*). Metode terakhir membutuhkan waktu eksekusi yang lebih lama karena memiliki proses penghitungan kemunculan dari sejumlah kombinasi dan pencarian untuk prediksi nilai dari matakuliah yang akan diambil dari *database*. Waktu komputasi yang dibutuhkan masing-masing metode berdasarkan tingkat kemampuan akademik mahasiswa dalam pengujian sebagaimana ditunjukkan pada Tabel 12, Tabel 13 dan Tabel 14.

Tabel 12. Waktu yang diperlukan pada data dengan tingkat Kemampuan Mahasiswa rata-rata

Metode	Waktu dalam second	Keterangan
<i>Wiener Transformation</i>	1.0239	
<i>K-means</i>	3.3591	3 iterasi
<i>Apriori</i>	88.2564	17 rule (prediksi)
Keseluruhan Metode (<i>K-Apriori</i>)	92.6394	

Tabel 13. Waktu yang diperlukan pada data dengan tingkat Kemampuan Mahasiswa Diatas rata-rata

Metode	Waktu dalam second	Keterangan
<i>Wiener Transformation</i>	1.1185	-
<i>K-means</i>	3.4144	3 iterasi
<i>Apriori</i>	45.4113	19 rule (prediksi)
Keseluruhan Metode (<i>K-Apriori</i>)	49.9442	-

Tabel 14. Waktu yang diperlukan pada data dengan Tingkat Kemampuan Mahasiswa Dibawah rata-rata

Metode	Waktu dalam second	Keterangan
<i>Wiener Transformation</i>	1.8841	
<i>K-means</i>	3.3100	3 iterasi
<i>Apriori</i>	61.5269	9 rule (prediksi)
Keseluruhan Metode (<i>K-Apriori</i>)	66.721	

5. Kesimpulan

5.1 Simpulan

Berdasarkan penelitian yang telah dilakukan, maka dapat ditarik beberapa kesimpulan sebagai berikut:

- 1) Metode *K-Apriori* dapat digunakan memprediksi nilai mata kuliah pilihan yang akan diambil sesuai dengan keminatan mahasiswa dengan memberikan *minimum confidence* dan *minimum support*.
- 2) Tingkat kemanfaatan dari *rule* yang dihasilkan terlihat berdasarkan dari *error rate* yang dihasilkan, Prediksi nilai matakuliah dapat digunakan dari pembangkitan *rule* terhadap mahasiswa yang memiliki IPK rendah ataupun tinggi. Hal ini ditunjukkan nilai *error rate* yang dihasilkan paling rendah dibandingkan mahasiswa yang memiliki IPK rata-rata.
- 3) Adapun waktu yang diperlukan paling tinggi dalam metode *K-Apriori* adalah pada tahapan pembentukan *rule* dengan menggunakan algoritma *Apriori*.

5.2 Saran

Berdasarkan penelitian yang dilakukan, penulis membutuhkan beberapa hal untuk pengembangan ke masa yang akan datang, yaitu :

- 1) Adanya hasil prediksi matakuliah yang akan diambil dengan mempertimbangkan nilai mata kuliah prasyaratnya sehingga sesuai dengan masukan yang dikehendaki *user*.
- 2) Oleh karena besarnya waktu yang diperlukan pada tahapan pembentukan *rule*, maka disarankan untuk menggunakan algoritma yang lain.

6. Daftar Rujukan

- [1] Dharmayanti, Dian. 2014, “Model Sistem Pendukung Keputusan Dalam Penentuan Mata Kuliah Pilihan di Jurusan Teknik Informatika Unikom.
- [2] D .Kurmar Ashok ., M.C, Annie Loraine Charlet. 2011. *Frequent Itemset Mining of Market Basket Data using K-Apriori Algorithm*. Departement Computer Science Government Arts College. Trichy. Tamil Nadu. India
- [3] D .Kurmar Ashok ., M.C, Annie Loraine Charlet. 2012. *Web Log Mining using K-Apriori Algorithm*. Departement Computer Science Government Arts College. Trichy. India. India.
- [4] Virgiawan, Donny Mitra., Mukhlash, Imam. 2013. “Aplikasi *Association Rule* Untuk Menemukan Pola Pada Data Mahasiswa Matematika ITS”. Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Teknologi Sepuluh Nopember. Surabaya.
- [5] Zins, Chaim. 2007. *Conceptual Approaches for Defining Data, Information and Knowledge*. Journal of the American Society for Information Science and Technology, 58(4):479–493, 2007. Israel.
- [6] Fadly, Ari. 2011. Konsep Data Mining. Komunitas eLearning IlmuKomputer.Com Copyright © 2003-2011 IlmuKomputer.Com.
- [7] Ikhsan, Muhammad ST., M.Kom., Dahria, Muhammad, SE., M.Kom., Sulindawaty M.Kom. 2013. “Penerapan *Association Rule* dengan Algoritma Apriori Pada Proses Pengelompokan Barang di Perusahaan Retail”. STMIK-Triguna Dharma. Medan Sumatra Utara, Indonesia.
- [8] McQueen J. 1967. *Some Methods for Classification and analysis of multivariate observations*, In Proc. of 5th Berkeley Symp Mathematics, statistics and probability, pp.281-296. University of California Los Angeles.
- [9] Diahpangastuti, Nucifera. 2012. Sistem Rekomendasi Bidang Minat Mahasiswa Menggunakan Metode *Association Rule* dan algoritma Apriori. Teknik Informatika FTIF-ITS.
- [10] Erwin. 2009. “Analisis *Market Basket* Dengan Algoritma Apriori dan FP-Growth”. Program studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Sriwijaya. Vol. 4 No. 2 (Juli 2009) Jurnal Generic.
- [11] Thangsupachai, Noppol., dkk. 2011. *Clustering Large Datasets with Apriori-Based Algorithm and Concurrent Processing. Proceedings of International MultiConference of Engineers and Computer Scientists 2011 Vol I, IMECS 2011, March 16-18, 2011. Hong Kong.*
- [12] Larose, T. Daniel. 2005. *Discovering Knowledge In Data An Introduction to Data Mining*. Central Connecticut State University.