

**PENGKLASIFIKASI KUALITAS MINUMAN ANGGUR
MENGGUNAKAN ALGORITMA *LEARNING VECTOR
QUANTIZATION* BERBASIS ASOSIASI**

SKRIPSI

Untuk memenuhi sebagian persyaratan

mencapai gelar Sarjana Komputer



Disusun oleh :

GEMA ADHA HERMANENDA

NIM. 0610960028

**PROGRAM STUDI INFORMATIKA/ILMU KOMPUTER
PROGRAM TEKNOLOGI INFORMASI DAN ILMU KOMPUTER
UNIVERSITAS BRAWIJAYA
MALANG
2013**

LEMBAR PERSETUJUAN

**PENGKLASIFIKASI KUALITAS MINUMAN ANGGUR
MENGGUNAKAN ALGORITMA LEARNING VECTOR
QUANTIZATION BERBASIS ASOSIASI**

SKRIPSI



Disusun oleh :

GEMA ADHA HERMANENDA

NIM. 0610960028

Telah diperiksa dan disetujui oleh :

Pembimbing I,

Pembimbing II,

Imam Cholissodin, S.Si.,M.Kom Ahmad Afif S., SSi., M.Kom
NIP. 850719 16 1 1 0422 NIP.820623 16 1 1 0425

LEMBAR PENGESAHAN

**PENGKLASIFIKASI KUALITAS MINUMAN ANGGUR
MENGGUNAKAN ALGORITMA LEARNING VECTOR
QUANTIZATION BERBASIS ASOSIASI**

SKRIPSI

Untuk memenuhi sebagian persyaratan
mencapai gelar Sarjana Komputer

Disusun oleh :

GEMA ADHA HERMANENDA
NIM. 0610960028

Skripsi ini telah diuji dan dinyatakan lulus tanggal 24 Juli 2013

Penguji I

Penguji II

Budi Darma S., S.Kom., M.Cs.
NIK. 841015 06 1 1 0030

N.Yudistira, S.Kom., M.Sc.
NIK. 831110 16 1 1 0425

Penguji III

AryoPinandito, S.T., M.MT.
NIK. 870724 06 1 1 0374

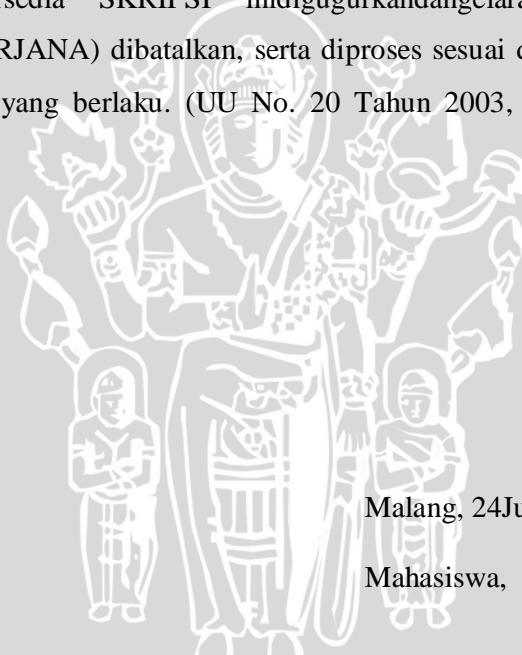
Mengetahui
Ketua Program Studi Teknik Informatika

Drs. Marji, MT
NIP. 196708011992031001

PERNYATAAN ORISINALITAS SKRIPSI

Saya menyatakan dengan sebenar-benarnya bahwa sepanjang pengetahuan saya, di dalam naskah SKRIPSI ini tidak terdapat karya ilmiah yang pernah diajukan oleh orang lain untuk memperoleh gelar akademik di suatu perguruan tinggi, dan tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang secara tertulis dikutip dalam naskah ini dan disebutkan dalam sumber kutipan dan daftar pustaka.

Apabila ternyata didalamnaskah SKRIPSI ini dapat dibuktikan terdapat unsur-unsur PLAGIASI, saya bersedia SKRIPSI ini digugurkan dan gelar akademik yang telah saya peroleh (SARJANA) dibatalkan, serta diproses sesuai dengan peraturan perundang-undangan yang berlaku. (UU No. 20 Tahun 2003, Pasal 25 ayat 2 dan Pasal 70).



Malang, 24 Juli 2013

Mahasiswa,

Gema Adha Hermanenda

NIM 0610960028

ABSTRAK

Secara umum, klasifikasi kualitas *wine* menggunakan dua cara, yaitu secara obyektif dan secara subyektif. Pengukuran obyektif dilakukan melalui tes laboratorium berdasarkan data senyawa kimia yang terdapat di dalam kandungan *wine*. Sedangkan pengukuran subyektif merupakan pengukuran yang dilakukan oleh pakar melalui analisa sensori dengan menilai langsung karakteristik *wine*. Analisa sensori membutuhkan *cost* dan waktu yang besar. Pengenalan pola dalam proses pengklasifikasian kualitas minuman anggur dapat membantu dalam proses pelabelan kelas dan dapat menggantikan peran pakar dalam pengklasifikasian *wine quality*.

Learning Vector Quantization (LVQ) merupakan suatu algoritma yang sering digunakan dalam pembelajaran jaringan syaraf tiruan dalam mengenali suatu pola. *Learning Vector Quantization* merupakan pembelajaran yang bersifat *supervised learning* yang dapat membangun polanya sendiri. Penambahan *association rule* basis asosiasi dapat memberikan hasil akurasi yang lebih baik terhadap hasil klasifikasi karena adanya penambahan bobot pada tiap atribut.

Data kualitas *wine* yang digunakan berasal dari UCI *Machine Learning*. Analisa hasil akurasi dari pengklasifikasian kualitas *wine* berdasarkan jumlah data benar dibandingkan dengan data uji. Dari hasil analisis didapatkan nilai *minimum support* dengan hasil akurasi terbaik pada 0 sampai dengan 0.04, *learning rate* 0.0201, dan maksimum epoch 2300 untuk *dataset red wine* dan 5000 untuk *dataset white wine*. Hasil akurasi dengan rata-rata kurang dari 60% dimungkinkan karena adanya *outlier* pada *dataset* dan adanya variasi pola data latih dengan data uji yang berbeda jauh sehingga data centroid yang diambil sebagai acuan tidak dapat mewakili pola data uji.

Kata Kunci : *Association Rule*, Basis Asosiasi, *Classification*, *Data Mining*, Jaringan Syaraf Tiruan, *Learning Vector Quantization*, *Wine Quality*.

ABSTRACT

In general, wine quality classification using two ways, objectively and subjectively. Objective measurements carried out through laboratory tests based on the data of chemical compounds contained in wine womb. While subjective measurements are measurements made by experts through sensory analysis to directly assess the characteristics of the wine. Sensory analysis requires huge cost and time. Pattern recognition in the process of classifying the quality of wine can help in the classroom and labeling process can replace the role of experts in the classification of wine quality.

Learning Vector Quantization (LVQ) is an algorithm that is often used in artificial neural networks in learning to recognize a pattern. Learning Vector Quantization learning is a supervised learning which can build their own pattern. Addition association association rule base can provide better accuracy results of the classification results due to the addition of weight to each attribute.

Wine quality data used come from the UCI Machine Learning. Analysis of the accuracy of the classification of wine quality based on the amount of data was compared with test data. From the analysis of minimum support values obtained with the best accuracy results at 0 to 0.04, learning rate of 0.0201, and the maximum epoch 2300 for red wine dataset and 5000 for white wine dataset. Results with an average accuracy of less than 60% is possible due to the presence of outliers in the dataset and the variation pattern of training data with test data so that the data is different from the centroid is taken as a reference can not represent the pattern of the test data.

Keywords: Association Rule, Base Association, Classification, Data Mining, Neural Networks, Learning Vector Quantization, Wine Quality.

KATA PENGANTAR

Alhamdulillah, segala puji dan syukur penulis ucapkan kepada Allah SWT karena atas rahmat dah hidayah-Nya sehingga penulis dapat menyelesaikan skripsi ini sebagai salah satu persyaratan dalam menyelesaikan studi di Program Studi Ilmu Komputer Program Teknologi Informasi dan Ilmu Komputer (PTIIK) Universitas Brawijaya.

Penulis menyadari bahwa skripsi ini dapat terselesaikan atas bantuan, petunjuk, dan bimbingan dari berbagai pihak yang telah membantu proses penyelesaiannya. Oleh karena itu, penulis mengucapkan terima kasih banyak kepada :

1. Imam Cholissodin, S.Si., M.Kom selaku Dosen Pembimbing I yang telah memberikan bimbingan dan arahan dengan penuh kesabaran sehingga skripsi ini dapat terselesaikan.
2. Ahmad Afif Supianto, SSi., M.Kom selaku Dosen Pembimbing II yang telah memberikan bimbingan dan arahan dengan penuh kesabaran sehingga skripsi ini dapat terselesaikan.
3. Edy Santoso, S.Si, M.Kom selaku Dosen Penasehat Akademik
4. Drs. Marji, MT selaku Ketua Program Studi Informatika/Ilmu Komputer Program Teknologi Informasi dan Ilmu Komputer Universitas Brawijaya.
5. Ir. Sutrisno, MT selaku Ketua Program Teknik Informatika dan Ilmu Komputer Universitas Brawijaya.
6. Segenap Bapak dan Ibu Dosen yang telah mendidik dan mengajarkan ilmunya kepada penulis selama menempuh pendidikan di Universitas Brawijaya.
7. Segenap staf dan karyawan PTIIK yang telah member banyak bantuan kepada penulis selama menyelesaikan skripsi ini..
8. Orang Tua, adik-adik dan segenap keluarga besar Bani Dawam yang tak henti-hentinya memberikan dukungan dan semangat terhadap penulis.
9. Seluruh rekan kerja PPTI Universitas Brawijaya yang telah member banyak bantuan dan bimbingan kepada penulis hingga terselesaikannya skripsi ini.

10. Teman teman Ilmu Komputer Angkatan 2006 yang telah banyak memberikan nasehat, bantuan, dan pengalaman selama menjadi mahasiswa di Universitas Brawijaya.
11. Semua pihak yang telah membantu terselesaikannya skripsi ini yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari bahwa skripsi ini masih banyak kekurangan dan jauh dari sempurna, karenaketerbatasan materi dan pengetahuan yang dimiliki penulis. Maka, saran dan kritik yang membangun dari semua pihak sangat diharapkan demi penyempurnaan selanjutnya. Semoga skripsi ini dapat bermanfaat dan berguna bagi semua pihak, baik penulis maupun pembaca, dan semoga Allah SWT meridhoi dan dicatat sebagai ibadah. Amin.

Malang, 2 Juli 2013

Penulis



DAFTAR ISI

	Halaman
SAMPUL	i
LEMBAR PERSETUJUAN	i
LEMBAR PENGESAHAN	ii
LEMBAR PERNYATAAN	iii
KATA PENGANTAR.....	iv
ABSTRAK.....	vi
ABSTRACT	vii
DAFTAR ISI.....	viii
DAFTAR GAMBAR.....	xii
DAFTAR TABEL	xiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian	3
1.4 Batasan Masalah.....	3
1.5 Manfaat.....	3
1.6 Metodologi Penelitian	3
1.7 Sistematika Penulisan.....	4
BAB II TINJAUAN PUSTAKA	6
2.1 Kajian Pustaka.....	6
2.2 Wine.....	6
2.2.1 Pengertian Wine	6
2.2.2 Dataset WineQuality.....	7
2.3 DataMining	8
2.3.1 Definisi DataMining.....	8
2.3.2 Proses DataMining	9
2.3.3 Fungsionalitas DataMining.....	10
2.4 Data Transformation.....	11
2.4.1 Normalisasi.....	12
2.5 Jaringan Syaraf Tiruan	13
2.5.1 Arsitektur Jaringan Syaraf Tiruan.....	14
2.5.2 Proses Pembelajaran.....	16
2.6 LearningVectorQuantization	17
2.6.1 LVQ 1	18
2.6.2 LVQ 2	19
2.6.3 Kondisi Berhenti	19
2.7 AssociationRule	20
2.8 Klasifikasi	21
2.9 Evaluasi	22
BAB III METODE PENELITIAN DAN PERANCANGAN	23
3.1 Studi Literatur	24
3.2 Data Penelitian	24
3.3 Analisa Sistem.....	26
3.3.1 Deskripsi Sistem.....	26

3.3.2 Batasan Sistem	26
3.4 Perancangan Proses	26
3.4.1 Transformasi Data	28
3.4.2 Pecah Data Transformasi	29
3.4.3 Proses Pencarian Bobot	33
3.4.4 Proses <i>LearningVectorQuantization</i>	37
3.4.5 Proses Klasifikasi	40
3.5 Perhitungan Manual.....	42
3.5.1 Dataset	42
3.5.2 Transformasi Data	43
3.5.3 Pencarian Bobot Pada Tiap Atribut.....	44
3.5.4 Pencarian Centroid Awal Pada Data Latih	46
3.5.5 Proses <i>LearningVectorQuantization</i>	46
3.5.6 Proses Klasifikasi	48
3.6 Perancangan Uji Coba	48
3.6.1 Pengujian untuk mengetahui pengaruh nilai <i>minimumsupport</i> dan <i>minimumconfidence</i> terhadap hasil akurasi	49
3.6.2 Pengujian untuk mengetahui pengaruh <i>learningrate</i> terhadap hasil akurasi.....	49
3.6.3 Pengujian untuk mengetahui pengaruh jumlah data terhadap hasil akurasi.....	50
3.6.4 Pengujian untuk mengetahui pengaruh <i>maximumepoch</i> terhadap hasil akurasi.....	51
BAB IV IMPLEMENTASI.....	52
4.1 Lingkungan Implementasi	52
4.1.1 Lingkungan Perangkat Keras	52
4.1.2 Lingkungan Perangkat Lunak	52
4.2 Implementasi Program.....	53
4.2.1 Implementasi Transformasi Data	53
4.2.2 Implementasi Pecah Data Transformasi	54
4.2.3 Proses Pencarian Bobot.....	55
4.2.4 Proses <i>LearningVectorQuantization</i>	57
4.2.5 Klasifikasi.....	59
4.3 Implementasi Antarmuka.....	60
4.3.1 Antarmuka Lihat Data	60
4.3.2 Antarmuka Input Parameter Pengujian	60
4.3.3 Antarmuka Hasil Pengujian	61
4.3.4 Antarmuka Hasil Perhitungan Normal.....	62
BAB V PENGUJIAN DAN ANALISIS	63
5.1 Pengujian	63
5.2 Hasil Uji.....	63
5.2.1 Pengujian untuk mengetahui pengaruh nilai <i>minimumsupport</i> dan <i>minimumconfidence</i> terhadap hasil akurasi	63
5.2.2 Pengujian untuk mengetahui pengaruh <i>learningrate</i> terhadap hasil akurasi.....	65
5.2.3 Pengujian untuk mengetahui pengaruh jumlah data terhadap hasil akurasi.....	66

5.2.4 Pengujian untuk mengetahui pengaruh <i>maximum epoch</i> terhadap hasil akurasi.....	68
5.3 Analisa Hasil.....	69
5.3.1 Analisa hasil untuk mengetahui pengaruh nilai <i>minimumsupport</i> dan <i>minimumconfidence</i> terhadap hasil akurasi	69
5.3.2 Analisa hasiluntuk mengetahui pengaruh <i>learningrate</i> terhadap hasil akurasi.....	70
5.3.3 Analisa hasiluntuk mengetahui pengaruh jumlah data terhadap hasil akurasi.....	71
5.3.4 Pengujian untuk mengetahui pengaruh <i>maximum epoch</i> terhadap hasil akurasi.....	72
BAB VI PENUTUP	73
6.1 Kesimpulan	73
6.2 Saran	74
DAFTAR PUSTAKA	75
LAMPIRAN	77



DAFTAR GAMBAR

	Halaman
Gambar 2.1 Proses Data Mining.....	10
Gambar 2.2 Arsitektur jaringan syaraf tiruan dengan lapisan tunggal	15
Gambar 2.3 Arsitektur jaringan syaraf tiruan dengan banyak lapisan.....	15
Gambar 3.1 Langkah-langkah penelitian	23
Gambar 3.2 Alur Proses Sistem.....	27
Gambar 3.3 Flowchart Normalisasi Data.....	29
Gambar 3.4 Flowchart Pecah Data	31
Gambar 3.5 Flowchart Pecah Data	32
Gambar 3.6 Flowchart Proses Pencarian Bobot	33
Gambar 3.7 Flowchart Konversi Array.....	34
Gambar 3.8 Flowchart Pencarian Group Support	35
Gambar 3.9 Flowchart Pencarian Group Confidence	36
Gambar 3.10 Flowchart Learning Vector Quantization	38
Gambar 3.11 Flowchart Learning Vector Quantization	39
Gambar 3.12 Flowchart Klasifikasi	41
Gambar 4.1 Source Code Konversi Data	53
Gambar 4.2 Source Code Normalisasi Data.....	54
Gambar 4.3 Source Code Pecah Data	55
Gambar 4.4 Source Code Pencarian Nilai Group Support.....	56
Gambar 4.5 Source Code Pencarian Group Confidence	57
Gambar 4.6 Source Code Perhitungan Nilai Bobot	57
Gambar 4.7 Source Code Learning Vector Quantizaton	59
Gambar 4.8 Source Code Klasifikasi.....	59
Gambar 4.9 Antarmuka Lihat Data.....	60
Gambar 4.10 Antarmuka Input Parameter Pengujian	61
Gambar 4.11 Antarmuka Hasil Pengujian	61
Gambar 4.12 Antarmuka Hasil Perhitungan Normal.....	62

DAFTAR TABEL

	Halaman
Tabel 3.1 Tabel Data Raw Perhitungan Manual.....	42
Tabel 3.2 Tabel Data Hasil Perhitungan Manual	43
Tabel 3.3 Tabel Group Support dan Group Confidence	45
Tabel 3.4 Tabel Bobot Atribut.....	46
Tabel 3.5 Tabel Centroid Awal	46
Tabel 3.6 Tabel Centroid Akhir.....	47
Tabel 3.7 Tabel rancangan pengujian pengaruh nilai minimum support dan minimum confidence	49
Tabel 3.8 Tabel rancangan pengujian pengaruh learning rate.....	50
Tabel 3.9 Tabel rancangan pengujian pengaruh jumlah data latih.....	50
Tabel 3.10 Tabel rancangan pengujian pengaruh maximum epoch.....	51
Tabel 5.1 Tabel hasil uji pengaruh nilai minimum support dan minimum confidence terhadap dataset red wine	64
Tabel 5.2 Tabel hasil uji pengaruh nilai minimum support dan minimum confidence terhadap dataset white wine.....	64
Tabel 5.3 Tabel hasil uji pengaruh learning rate terhadap dataset red wine	65
Tabel 5.4 Tabel hasil uji pengaruh learning rate terhadap dataset white wine	66
Tabel 5.5 Tabel hasil uji pengaruh jumlah data latih terhadap dataset red wine.....	67
Tabel 5.6 Tabel hasil uji pengaruh jumlah data latih terhadap dataset white wine	67
Tabel 5.7 Tabel hasil uji pengaruh max epoch terhadap dataset red wine	68
Tabel 5.8 Tabel hasil uji pengaruh max epoch terhadap dataset white wine.....	69

BAB I

PENDAHULUAN

1.1 Latar Belakang

Wine merupakan minuman sari buah anggur yang telah mengalami proses fermentasi. Berdasarkan data yang diambil dari *wineinstitute.org*, tingkat kebutuhan konsumsi *wine* pada sepuluh tahun terakhir mengalami peningkatan sebesar 35%. Pada tahun 2002 dibutuhkan 552 juta galon *wine* setiap tahun untuk memenuhi kebutuhan, dan pada tahun 2012, kebutuhan *wine* meningkat menjadi 749 juta gallon. Bertambahnya tingkat konsumsi *wine* berbanding lurus dengan tingkat produksinya. Untuk mendukung tingkat produksi, dibutuhkan teknologi yang dapat mempercepat proses produksi dan proses pengelompokan *wine quality*.

Pada umumnya pengklasifikasian *wine quality* menggunakan dua cara, yaitu pengukuran obyektif dan pengukuran subyektif. Pengukuran obyektif dilakukan melalui tes laboratorium berdasarkan data senyawa kimia yang terdapat di dalam kandungan *wine*, misalnya kadar alkohol, tingkat keasaman, dll. Sedangkan pengukuran subyektif merupakan pengukuran yang dilakukan oleh seorang pakar melalui analisa sensori dengan menilai langsung karakteristik *wine*, misalnya warna, rasa, dan aroma. Hubungan antara data kimia fisik dan analisa sensori sangat komplek. Menurut Smith (2005), walaupun analisa kimia dan analisa sensori *wine* dikembangkan secara terpisah, kemajuan dalam teknik analisa data multivariat memungkinkan komposisi kimia yang terkandung dalam *wine* terhubung dengan karakteristik sensori yang dimiliki. Analisa sensori membutuhkan biaya yang mahal dan waktu yang lama. Selain itu, pengklasifikasian *wine* berdasarkan analisa sensori merupakan analisa yang bersifat subyektif.

Pengenalan pola dalam proses pengklasifikasian kualitas minuman anggur dapat membantu dalam proses pelabelan kelas. Sehingga pengenalan pola terhadap minuman anggur dapat mengantikan peran pakar dalam pengklasifikasian *wine quality*. Salah satu bidang dalam ilmu komputer yang berkaitan dengan pengenalan pola adalah jaringan syaraf tiruan. Dimana jaringan

tersebut dapat melakukan pembelajaran dalam mengenali polanya sendiri. *Learning Vector Quantization* (LVQ) merupakan suatu algoritma yang sering digunakan dalam pembelajaran jaringan syaraf tiruan dalam mengenali suatu pola. *Learning Vector Quantization* merupakan pembelajaran yang bersifat *supervised learning*. Metode ini dalam proses pembelajarannya, akan mereposisikan pusat kelas berdasarkan jarak dan kelas yang menjadi acuan dari data latih. Dengan menggunakan metode ini, diharapkan metode ini dapat mengenali pola yang muncul dari data kimia yang terkandung dalam *wine* sehingga dapat digunakan dalam pengklasifikasian *wine quality* yang mempunyai jumlah data besar.

Penelitian tentang metode *Learning Vector Quantization* pernah dilakukan sebelumnya oleh Marchin Blachnik dan Włodzisław Duch pada tahun 2011. Dalam penelitiannya, metode LVQ diterapkan terhadap beberapa dataset dengan rata-rata hasil akurasi pada *dataset Sonar* 82.2%, *dataset WBC* 96%, *dataset Spam* 86.9%, *dataset Pima Indian* 75%, *dataset Cleveland* 82.8%, *dataset Ionosphere* 87.2% dan *dataset Appendicitis* 87.8%.

Penelitian pengklasifikasian kualitas *wine* sendiri pernah dilakukan oleh Paulo Cortez dengan menggunakan metode SVM dan Made Putra dengan menggunakan metode KNN-BA (Berbasis Assosiasi). Dari penelitian yang dilakukan oleh Cortez (Cortez, 2009), didapatkan hasil akurasi 62.4% untuk data *red wine* dan 64,6% untuk data *white wine*. Sedangkan dari penelitian yang dilakukan oleh Made Putra, didapatkan hasil akurasi 71,92% untuk data *red wine* dan 68,23% untuk data *white wine*. Dengan adanya penambahan *association rule* metode BA (Berbasis Asosiasi) pada metode KNN yang diterapkan. Penambahan metode Basis Asosiasi memberikan bobot tersendiri pada tiap atribut senyawa kimia yang terdapat pada *dataset wine quality*. Pemberian bobot pada tiap atribut dapat menghasilkan tingkat akurasi yang lebih baik (Made Putra, 2011).

Berdasarkan latar belakang yang telah dipaparkan, judul yang diambil pada skripsi ini yaitu **“Pengklasifikasian Kualitas Minuman Anggur Menggunakan Algoritma LVQ (*Learning Vector Quantization*) Berbasis Asosiasi”**.

1.2 Rumusan Masalah

1. Bagaimana proses dari algoritma *Learning Vector Quantization* berbasis asosiasi terhadap *dataset wine quality*?
2. Bagaimana tingkat akurasi yang diperoleh dari algoritma *Learning Vector Quantization* berbasis asosiasi terhadap pengklasifikasian *wine quality* dibandingkan dengan penelitian sebelumnya?

1.3 Tujuan

1. Memahami proses dari algoritma *Learning Vector Quantization* berbasis asosiasi terhadap *dataset wine quality*.
2. Mengetahui tingkat akurasi yang diperoleh dari algoritma *Learning Vector Quantization* berbasis asosiasi terhadap pengklasifikasian *wine quality* dibandingkan dengan penelitian sebelumnya.

1.4 Batasan Masalah

Oleh karena besarnya permasalahan, maka agar pembahasan tidak menyimpang dari tujuan dilakukan pembatasan masalah sebagai berikut,

1. *Dataset Wine Quality* diambil dari UCI *Machine Learning*.
2. *Dataset* merupakan data *Wine Quality* yang diambil pada tahun 2009.
3. Jumlah *dataset red wine* sebanyak 1599 data dan *dataset white wine* sebanyak 4898 data.
4. *Dataset* memiliki 10 kelas dan memiliki 11 fitur yang berupa data senyawa kimia yang terkandung di dalamnya.

1.5 Manfaat

1. Memahami proses *Learning Vector Quantization* berbasis asosiasi jika diterapkan pada dataset *wine quality*.
2. Menghasilkan sistem yang dapat mengklasifikasian *wine quality* secara otomatis yang dapat membantu proses produksi berdasarkan data senyawa kimia.

1.6 Metode Penelitian

Metode penyelesaian masalah yang dilakukan pada skripsi ini, yaitu :

1. Studi literatur.

Mempelajari dan mengkaji beberapa literatur (jurnal, buku, dan artikel dari website) yang berkaitan *wine*, *wine quality*, data mining, basis asosiasi dan algoritma *Learning Vector Quantization*.

2. Perumusan masalah dan analisa kebutuhan

Mengkaji permasalahan sebagai hasil dari studi pustaka dan menganalisis yang dibutuhkan.

3. Perancangan dan Implementasi sistem

Menerapkan algoritma *Learning Vector Quantization berbasis asosiasi* dengan mendesain dan membangun sebuah sistem untuk menemukan hasil klasifikasi pada *dataset wine quality*.

4. Uji coba dan analisis hasil implementasi

Menganalisa nilai minimum group support, minimum group confidence, learning rate, jumlah data latih dan maximum epoh yang dapat menghasilkan akurasi terbaik.

1.7 Sistematika Penulisan

Sistematika penulisan skripsi ini dibagi menjadi lima bab dengan masing-masing bab diuraikan sebagai berikut:

1. BAB I PENDAHULUAN

Berisi latar belakang masalah, perumusan masalah, batasan masalah, tujuan penulisan, manfaat penulisan, dan sistematika penulisan.

2. BAB II TINJAUAN PUSTAKA

Bab ini menjelaskan tentang *wine*, *wine quality*, basis asosiasi, jaringan syaraf tiruan, data mining, *Learning Vector Quantization*.

3. BAB III METODOLOGI DAN PERANCANGAN SISTEM

Bab ini membahas analisa permasalahan, metode penyelesaian, perancangan sistem, dan contoh perhitungan manualnya.

4. BAB IV IMPLEMENTASI

Pada bab ini akan dilakukan implementasi sistem yang telah dirancang sebelumnya.

5. BAB V ANALISA DAN PEMBAHASAN

Pada bab ini akan dilakukan analisa dari hasil yang diperoleh dari sistem yang telah dibuat untuk mengklasifikasikan kualitas minuman anggur menggunakan algoritma *Learning Vector Quantization* berbasis asosiasi.

6. BAB VI KESIMPULAN DAN SARAN

Bab ini berisi kesimpulan dari proses perancangan hingga proses implementasi sistem dan saran untuk pengembangan lebih lanjut.



BAB II

TINJAUAN PUSTAKA

Pada bab ini akan diuraikan mengenai teori-teori dasar pembuatan aplikasi Pengklasifikasian Kualitas Minuman Anggur Menggunakan Algoritma LVQ (*Learning Vector Quantization*), diantaranya sebagai berikut:

4.1 Kajian Pustaka

Penelitian yang saya tulis ini merupakan penggabungan dua metode jaringan syaraf tiruan *Learning Vector Quantization* dan *Association Rule* basis asosiasi. Dimana *association rule* ini digunakan untuk memperoleh bobot tiap atribut yang akan dijadikan sebagai acuan bobot pada proses perhitungan jarak dalam *learning vector quantization* dan proses perhitungan jarak dalam klasifikasi.

Dalam kajian pustaka pada pengklasifikasian kualitas minuman anggur menggunakan metode KNN Berbasis Asosiasi yang ditulis oleh Made Putra, penambahan *association rule* basis asosiasi digunakan untuk memperoleh bobot pada tiap atribut *dataset wine quality*. Penambahan bobot bertujuan untuk mengetahui pola sebaran nilai atribut pada *dataset* dan untuk mengetahui atribut mana yang relevan dalam pengaruh perhitungan jarak pada proses klasifikasi.

Learning Vector Quantization (LVQ) merupakan salah satu metode dalam jaringan syaraf tiruan. Marchin Blachnik dan Włodzisław Duch pada tahun 2011 melakukan penelitian terhadap *dataset* Pima Indian dengan menambahkan bobot pada penelitiannya menggunakan LVQ. Metode LVQ digunakan untuk mencari titik pusat kelas pada *dataset* yang dijadikan acuan untuk proses klasifikasi.

4.2 Wine

2.2.1 Pengertian Wine

Wine atau minuman anggur merupakan sari buah yang difermentasi (Seldon, 2000). Pada umumnya, buah anggur digunakan sebagai bahan baku dalam proses pembuatannya.

Metode yang dapat digunakan untuk penilaian kualitas *wine* yaitu pengukuran objektif (misalnya analisa senyawa volatil) dan pengukuran subjektif (misalnya analisa sensori) yang dapat memberikan informasi yang handal tentang kualitas *wine* (Smyth, 2005). Pengukuran objektif melalui tes laboratorium digunakan untuk mengetahui data kimia fisik *wine* seperti: kerapatan, kadar alkohol atau nilai pH. Sedangkan pengukuran subjektif melalui analisa sensori dilakukan dengan menilai karakteristik *wine* (uji rasa, warna dan bau) oleh pakar.

2.2.2 Dataset Wine Quality

Dari data yang diambil dari UCI Machine Learning, *dataset wine quality* terbagi atas dua jenis, yaitu *red wine* dan *white wine*. *Dataset red wine* memiliki 1599 instances, 11 atribut, dan mempunyai jangkauan kelas, kelas 1 sampai dengan kelas 10, namun data tersebar pada kelas 3 sampai dengan kelas 8. Sedangkan pada dataset *white wine* memiliki 4898 instances, 11 atribut, dan mempunyai jangkauan kelas, kelas 1 sampai dengan kelas 10, namun data tersebar pada kelas 3 sampai dengan kelas 9.

Data kimia fisik meliputi: (Jackson, 2008; Simmonds, 1919)

- *Fixed acidity* merupakan semua asam organik yang tidak termasuk dalam kategori *volatile*/mudah menguap. Asam ini secara kuantitatif mengatur pH dari *wine*.
- *Volatile acidity* merupakan asam yang dapat dengan mudah dihilangkan dengan destilasi uap. Asam ini menciptakan aroma pedas dari *wine*. Kadar *volatile acidity* dari *wine* yang baik adalah di bawah 1,2 g/L.
- *Citric acid* atau asam sitrat merupakan asam yang banyak ditemukan pada buah-buahan termasuk anggur. Asam ini memberikan rasa segar. *Wine* yang baik, memiliki kadar di asam sitrat bawah 1 g/L.
- *Residual sugar* merupakan sisa gula yang terdapat pada *wine* setelah proses fermentasi selesai. Banyaknya *residual sugar* mempengaruhi rasa manis dari *wine*.
- *Chlorides* berfungsi untuk mengatur pH agar tetap berada dalam rentang yang dapat diterima.

- *Free sulfur dioxide* merupakan sulfit yang masih belum bereaksi dengan molekul lain, misalnya gula.
- *Total sulfur dioxide* merupakan *total free sulfur dioxide* dan sulfit yang telah bereaksi dengan molekul lain pada *wine*.
- *Density* berkaitan dengan jumlah gula terlarut dalam *wine*. Nilai standar *density* bernilai antara 0.987 sampai 1.076 g/cm³
- pH berhubungan dengan keasaman *wine*. Nilai pH yang sesuai pada *wine* berkisar 2.9 hingga 4.2.

2.3 Data Mining

2.3.1 Definisi Data Mining

Terdapat beberapa definisi data mining dari beberapa pendapat, sebagai berikut:

1. Secara sederhana, definisi dari data mining adalah ekstraksi informasi atau pola yang penting atau menarik dari data yang ada di database yang besar (Sucahyo, 2003).
2. Menurut Han dan Kamber (2000), data mining berarti mengekstrak atau menambang pengetahuan dari sejumlah besar data. Data mining adalah proses menemukan pengetahuan yang menarik dari sejumlah besar data yang disimpan dalam *database*, *warehouse*, atau tempat penyimpanan informasi lainnya.
3. Data mining merupakan analisis terhadap pengamatan kumpulan data untuk menemukan hubungan tak terduga dan untuk meringkas data dengan cara yang baru sehingga dapat dimengerti serta bermanfaat bagi pemilik data (Hand, 2001).
4. Data mining adalah suatu algoritma di dalam menggali informasi berharga yang terpendam atau tersembunyi pada suatu koleksi data (*database*) yang sangat besar sehingga ditemukan suatu pola yang menarik yang sebelumnya tidak diketahui (Haireyanov, 2004).

Berdasarkan beberapa definisi tersebut, maka definisi data mining adalah menggali atau mengestrak informasi tersembunyi pada sejumlah besar data yang

disimpan dalam *repository* untuk menemukan suatu pola atau hubungan tak terduga sehingga bermanfaat bagi pemilik data.

2.3.2 Proses Data Mining

Prosedur yang umum digunakan untuk permasalahan data mining meliputi tahap-tahap sebagai berikut: (Kantardzic, 2003)

1. Menentukan permasalahan dan merumuskan hipotesis.

Pada tahap ini, ditentukan variable-variabel yang akan digunakan dan meyimpulkan hipotesis awal pada suatu permasalahan data mining.

2. Mengumpulkan data

Pada tahap ini, dilakukan pengumpulan data yang akan diproses lebih lanjut oleh sistem.

3. Preprocessing data

Pada tahap ini, dilakukan penanganan masalah terhadap adanya *outlier*, penanganan *missing value*, dan transformasi data.

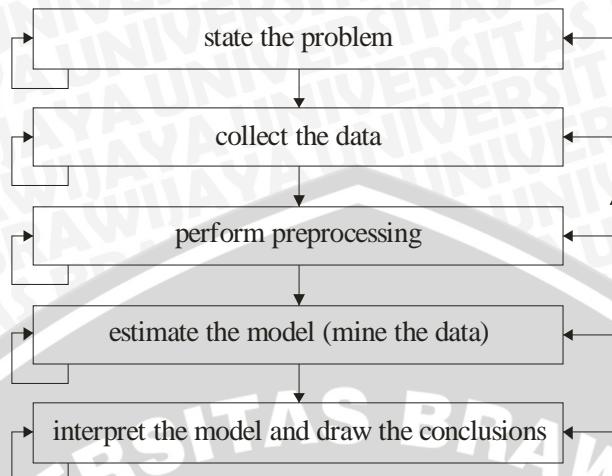
4. Memperkirakan model

Pada tahap ini, dilakukan pemilihan dan penerapan teknik data mining yang sesuai dengan masalah yang ada.

5. Menafsirkan model dan menarik kesimpulan

Pada tahap ini, dilakukan penafsiran model untuk membantu dalam pengambilan keputusan dan analisa hasil.

Tahap-tahap atau proses pada data mining ditampilkan oleh Gambar 2.1.



Gambar 2.1 Proses Data Mining (Kantardzic, 2003)

2.3.3 Fungsionalitas Data Mining

Fungsionalitas data mining digunakan untuk menentukan jenis pola yang dapat ditemukan dalam tugas data mining. Pada umumnya terdapat dua kategori dalam tugas data mining, yaitu deskriptif dan prediktif. *Descriptive mining* mengkarakterisasi sifat-sifat umum dari data dalam database. *Predictive mining* mengambil kesimpulan pada data yang ada, dalam rangka untuk membuat prediksi (Han dan Kamber, 2000).

Menurut Kantardzic (2003), tujuan data mining yang berkaitan dengan prediksi adalah menghasilkan model yang dapat digunakan untuk klasifikasi, prediksi atau estimasi. Sedangkan tujuan data mining yang berkaitan dengan deskripsi adalah memperoleh pemahaman sistem yang dianalisa dengan mengungkap pola dan hubungan dalam kumpulan data yang besar.

Terdapat beberapa fungsionalitas data mining, sebagai berikut: (Han dan Kamber, 2000; Moertini, 2002)

1. Analisis asosiasi

Menemukan aturan (*rule*) asosiasi yang menunjukkan kondisi nilai atribut yang sering ada bersamaan dalam satu kumpulan data.

2. Klasifikasi

Fungsi pembelajaran yang memetakan (mengklasifikasi) sebuah item data ke dalam salah satu dari beberapa kelas yang sudah didefinisikan.

3. *Clustering*

Melakukan pengelompokan data tanpa berdasarkan kelas data tertentu.

4. Pendekripsi perubahan dan deviasi

Berfokus pada penemuan perubahan yang paling signifikan di dalam data dari nilai-nilai yang telah diukur sebelumnya.

2.4 Data Transformation

Proses data mining membutuhkan integrasi data dari berbagai data penyimpanan. Data perlu diubah untuk bisa melalui proses data mining atau *pattern discovery*. Dalam transformasi data, data ditransformasikan ke dalam bentuk yang sesuai untuk data mining (Jiawei H dan Michelin Kamber, 2006). Menurut Jiawai dan Kamber data trasformasi dapat dilakukan dengan cara berikut:

Smoothing, yang bekerja untuk menghilangkan noise dari data. Teknik – teknik tersebut meliputi binning, regresi, dan clustering.

Aggregation, digunakanya ringkasan atau agregasi operasi diterapkan pada data. Misalkan untuk penjumlahn data harian dapat dikumpulkan sehingga untuk menghitung total bulanan dan tahunan. Langkah ini digunakan dalam membangun sebuah data kubus untuk analisa data pada beberapa *multiple granularities*.

Generalization, dari data tingkat rendah atau primitive, data diganti dengan *higher-level concepts* dengan menggunakan *concept hirerarchies*. Sebagai contoh atribut kategori, seperti jalan dapat digeneralisasi untuk tingkat yang lebih tinggi dengan menggunakan nama kota atau negara. Demikian juga nilai untuk atribut numerik, seperti usia dapat dipatenkan ketingkat lebih tinggi, seperti pemuda, setengah baya dan senior.

Normalization, dimana data atribut ditingkatkan sehingga jatuh dalam jangkau terkecil, seperti -1.0 menjadi 1.0 atau untuk 0.0 menjadi 1.0.

Attribute construction, (konstruksi fitur), dimana atribut dibangun dan menambahkan dari himpunan atribut untuk membantu proses data mining.

2.4.1 Normalisasi

Atribut cenderung memiliki nilai dengan rentang yang sangat bervariasi.

Misalnya, dalam menentukan jarak antara dua *record*, atribut dengan rentang nilai yang besar, memiliki lebih banyak pengaruh dalam menentukan jarak daripada atribut dengan rentang nilai yang kecil. Oleh karena itu, perlu dilakukan transformasi data berupa normalisasi terhadap nilai untuk membakukan skala pengaruh yang ada pada atribut, terhadap hasil. Ada beberapa teknik normalisasi data seperti normalisasi min-max dan Z-score (Moradian dan Baarani, 2009; Larose, 2005).

Dari beberapa metode data mining, pada dasarnya menggunakan perhitungan jarak antar record pada *n-dimensional space*, dibutuhkan proses normalisasi agar didapatkan data yang bagus untuk proses lebih lanjut. Perhitungan dari hasil normalisasi dapat diskalakan menjadi rentang nilai yang spesifik, misalnya [-1,1] atau [0,1]. Jika tidak dilakukan proses normalisasi, perhitungan jarak antar record akan kacau dikarenakan dimungkinkan nilai pada atribut yang berbeda memiliki karakteristik yang berbeda. Terdapat banyak cara untuk proses normalisasi data. Berikut terdapat tiga cara umum dalam melakukan proses transformasi,

1. *Decimal Scaling*
2. *Min-max Normalization*
3. *Standard Deviation Normalization*

Dalam skripsi ini digunakan normalisasi min-max. Normalisasi min-max dihitung dengan persamaan 2.1 (Moradian dan Baarani, 2009). Menurut Jayalakshmi dan Santhakumaran (2011) normalisasi mix-max memiliki keunggulan yaitu menjaga relasi pada data.

$$V' = \frac{V - \min_A}{\max_A - \min_A} \quad (2.1)$$

di mana,

V' : hasil normalisasi yang nilainya berkisar antara 0 dan 1

V : nilai atribut A yang akan dinormalisasi

minA : nilai minimum dari suatu atribut, A

maxA : nilai maksimum dari suatu atribut, A.

2.5 Jaringan Syaraf Tiruan

Jaringan syaraf tiruan adalah paradigma pemrosesan suatu informasi yang terinspirasi oleh sistem sel syaraf biologi, sama seperti otak yang memproses suatu informasi. Elemen mendasar dari paradigma tersebut adalah struktur yang baru dari sistem pemrosesan informasi (Yani, 2005). Jaringan syaraf tiruan, seperti manusia, belajar dari suatu contoh. Jaringan syaraf tiruan dibentuk untuk memecahkan suatu masalah tertentu seperti pengenalan pola atau klasifikasi melalui proses pembelajaran.

Jaringan syaraf tiruan telah dikembangkan dengan menggunakan model matematis untuk menirukan cara kerja jaringan syaraf biologis, dengan berdasarkan asumsi (Kusumadewi, 2003):

- a. Pengolah informasi terdiri dari elemen-elemen sederhana yang disebut neuron.
- b. Sinyal dilewatkan dari satu neuron ke neuron yang lain melalui hubungan koneksi.
- c. Tiap hubungan koneksi mempunyai nilai bobot tersendiri.
- d. Tiap neuron mempergunakan fungsi aktivasi (biasanya tidak linear) terhadap masukan yang diterimanya untuk menentukan sinyal keluarannya.

Jaringan syaraf tiruan memiliki pendekatan yang berbeda untuk memecahkan masalah dibandingkan dengan sebuah komputer konvensional. Umumnya komputer konvensional menggunakan pendekatan algoritma (komputer konvensional menjalankan sekumpulan perintah untuk memecahkan masalah). Jika suatu perintah tidak diketahui oleh komputer konvensional maka computer konvensional tidak dapat memecahkan masalah yang ada.

Sangat penting mengetahui bagaimana memecahkan suatu masalah pada komputer konvensional dimana computer konvensional akan sangat bermanfaat jika dapat melakukan sesuatu dimana pengguna belum mengatahui bagaimana melakukannya. Dalam hal ini penggunaan jaringan syaraf tiruan dibutuhkan untuk

mengenali pola berita baik yang sudah dilatihkan maupun yang belum pernah dilatihkan.

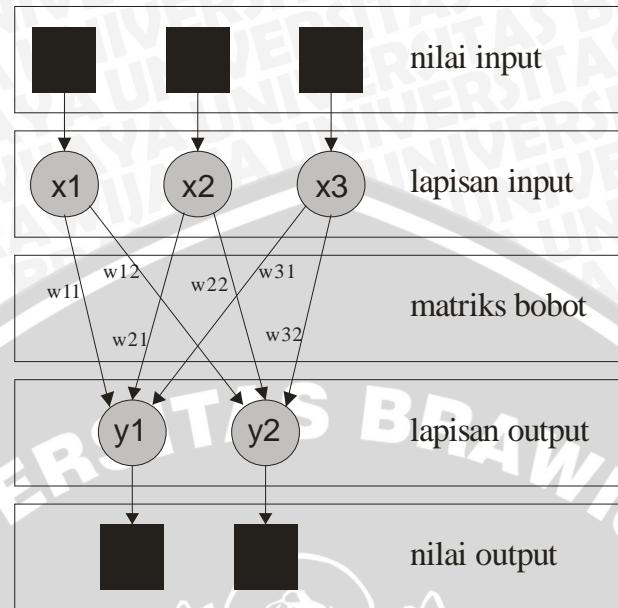
2.5.1 Arsitektur Jaringan Syaraf Tiruan

Jaringan syaraf tiruan terdiri dari neuron-neuron yang dikelompokkan dalam berbagai lapisan. Pada umumnya, lapisan-lapisan yang berada pada lapisan yang sama akan memiliki keadaan yang sama. Faktor yang menentukan keadaan suatu neuron adalah fungsi aktivasi dan pola bobotnya. Untuk neuron pada lapisan yang sama akan memiliki fungsi aktivasi yang sama pula. Apabila neuron-neuron yang terletak pada lapisan yang sama akan dihubungkan dengan neuron-neuron pada lapisan yang lain, maka setiap neuron yang terletak pada lapisan tersebut juga harus dihubungkan dengan setiap lapisan pada lapisan lainnya. Misalkan akan dihubungkan neuron-neuron pada lapisan tersembunyi dengan neuron-neuron pada lapisan output, maka setiap neuron pada lapisan tersembunyi harus dihubungkan dengan setiap neuron pada lapisan output.

Ada beberapa arsitektur jaringan syaraf tiruan, diantaranya (Kusumadewi, 2003):

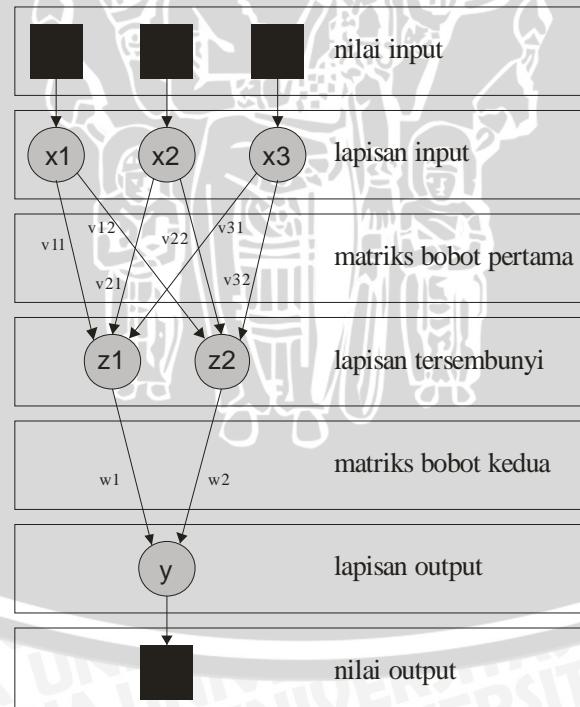
- a. Jaringan dengan lapisan tunggal (*single layer net*)

Sesuai dengan namanya, jaringan ini hanya memiliki satu lapisan dengan bobot-bobot terhubung. Jaringan ini hanya menerima input kemudian secara langsung akan mengolahnya menjadi output tanpa melalui lapisan tersembunyi.



Gambar 2.5 menunjukkan arsitektur jaringan syaraf tiruan dengan lapisan tunggal.

b. Jaringan dengan banyak lapisan (*multilayer net*)



Gambar 2.6 menunjukkan arsitektur jaringan syaraf tiruan dengan banyak lapisan.

Jaringan dengan banyak lapisan mempunyai satu atau lebih lapisan yang terletak diantara lapisan input dengan lapisan output. Lapisan ini disebut sebagai lapisan tersembunyi (*hidden layer*). Jaringan yang mempunyai banyak lapisan ini dapat menyelesaikan permasalahan yang lebih sulit daripada lapisan tunggal, tentu dengan pembelajaran yang lebih rumit. Akan tetapi, pada beberapa kasus, pembelajaran pada jaringan yang mempunyai banyak lapisan ini lebih sukses dalam menyelesaikan masalah.

2.5.2 Proses Pembelajaran

Jaringan syaraf akan mencoba untuk mensimulasikan kemampuan otak manusia untuk belajar. Jaringan syaraf tiruan juga tersusun atas neuron-neuron dan dendrit. Tidak seperti model biologis, jaringan syaraf memiliki struktur yang tidak dapat diubah, dibangun oleh sejumlah neuron, dan memiliki nilai tertentu yang menunjukkan seberapa besar koneksi antar neuron (yang dikenal dengan nama bobot). Perubahan yang terjadi selama proses pembelajaran adalah perubahan nilai bobot. Nilai bobot akan bertambah jika informasi yang diberikan oleh neuron yang bersangkutan tersampaikan, sebaliknya jika informasi tidak disampaikan oleh neuron ke neuron yang lain, maka nilai bobot yang menghubungkan keduanya akan dikurangi. Pada saat pembelajaran dilakukan pada input yang berbeda, maka nilai bobot akan diubah secara dinamis hingga mencapai suatu nilai yang cukup seimbang.

Apabila nilai ini telah tercapai, mengindikasikan bahwa tiap-tiap input telah berhubungan dengan output yang diharapkan.

Ada dua jenis proses pembelajaran yaitu (Kusumadewi, 2003):

- a. Pembelajaran terawasi (*supervised learning*) Metode pembelajaran pada jaringan syaraf disebut terawasi jika target output yang diharapkan telah diketahui sebelumnya.
- b. Pembelajaran tak terawasi (*unsupervised learning*) Pada metode pembelajaran yang tak terawasi ini tidak memerlukan target output. Pada metode ini tidak dapat ditentukan hasil yang seperti apakah yang diharapkan selama proses pembelajaran.

Di dalam proses pembelajaran, *learning rate* adalah sebuah variabel yang nilainya diantara 0 sampai 1 yang berguna untuk menentukan laju pembelajaran. Sedangkan *max epoch* adalah batas maksimum perulangan untuk melakukan proses pembelajaran.

2.6 Learning Vector Quantization

Learning Vector Quantization (LVQ) merupakan salah satu metode dalam jaringan syaraf tiruan yang telah digunakan secara luas dalam proses pengenalan pola. LVQ pertama kali diperkenalkan oleh Teuvo Kohonen sebagai algoritma *clustering* yang didasarkan pada sekumpulan prototipe. Pemikiran tersebut dikombinasikan dengan *self-organizing learning* namun menggunakan pelatihan yang terawasi. Kegunaan metode LVQ sering dijumpai pada aplikasi-aplikasi data mining, robotik, maupun pengenalan *linguistic* (Kohonen, dkk., 1996).

LVQ merupakan metode yang mudah dipahami dan diterapkan. Penentuan klasifikasi suatu dari sekumpulan vector dilakukan dengan membandingkan jarak euclidean vektor-vektor tersebut dengan sejumlah vektor-vektor prototipe yang merepresentasikan kelas dari sekumpulan data dalam klasifikasi yang sama.

LVQ adalah suatu metode untuk melakukan pembelajaran pada lapisan kompetitif yang terawasi. Suatu lapisan kompetitif akan secara otomatis belajar untuk mengklasifikasikan vektor-vektor input. Kelas-kelas yang didapatkan sebagai hasil dari lapisan kompetitif ini hanya tergantung pada jarak antara vektor-vektor input. Jika 2 vektor input mendekati sama maka lapisan kompetitif akan meletakkan kedua vektor input tersebut ke dalam kelas yang sama (Kusumadewi, 2003).

Pada proses pembelajaran, suatu vektor prototipe akan mengalami perubahan yang akan semakin memperjelas klasifikasi. Adapun vektor prototipe yang mengalami perubahan tersebut adalah vektor pemenang, yaitu vektor prototipe yang terdekat (jarak Euclidean-nya) terhadap vektor input. Dalam hal ini berlaku skema *Winner Takes All* (WTA), karena perubahan signifikan hanya dialami oleh vektor prototipe pemenang dengan jarak Euclidean terkecil (Biehl, 2005).

2.6.1 LVQ 1

LVQ 1 ini merupakan algoritma dasar LVQ. Inti dari algoritma ini adalah pelatihan yang bertujuan untuk mengklasifikasikan vektor input ke dalam kelas prototipe yang tersedia.

Proses pembelajaran pada algoritma LVQ 1 diawali dengan inisialisasi secara acak untuk memilih vektor-vektor yang berlaku sebagai prototipe. Kemudian dilakukan perulangan hingga ditemukan kondisi berhenti, dimana dalam setiap perulangan dilakukan penentuan prototipe yang terdekat dari vektor input. Kemudian vektor prototipe tersebut akan mengalami perubahan yang bersifat mendekati atau menjauh dari vektor input, tergantung pada kecocokan terhadap target pelatihan. Apabila target pelatihan sesuai dengan vektor prototipe terdekat dari vektor input, maka vektor prototipe akan berubah mendekati vektor input. Sebaliknya apabila target pelatihan tidak sesuai dengan vektor prototipe terdekat dari vektor input, maka vektor prototipe akan berubah menjauhi vektor input. Penentuan kedekatan antara vektor input ke vektor prototipe ditentukan dengan menggunakan jarak *euclidean*.

Persamaan 2.2, 2.3. 2.4.a, dan 2.4.b menjelaskan proses dasar yang terjadi pada algoritma LVQ 1.

$$c = \arg \min\{\|x - m_i\|\} \quad (2.2)$$

$$d = \sum_{i=1}^n |x_i - w_i| \quad (2.3)$$

$$m_c(t+1) = m_c(t) + \alpha(t)[x(t) - m_c(t)] \quad (2.4.a)$$

Jika x dan m_c termasuk dalam kelas yang sama

$$m_c(t+1) = m_c(t) - \alpha(t)[x(t) - m_c(t)] \quad (2.4.b)$$

Jika x dan m_c tidak termasuk dalam kelas yang sama

$$m_i(t+1) = m_i(t) \quad (2.4.c)$$

Untuk vector-vektor yang lain dimana $i \neq c$.

Dimisalkan terdapat sejumlah i vektor prototipe, m_i (disebut juga *codebook vector*). Vektor m_c merupakan vektor prototipe dengan jarak *Euclidean* d terkecil, dimana c didapatkan dari persamaan 2.2, dan jarak *Euclidean* d didapat dengan

persamaan 2.3. Pada persamaan 2.4.a dan 2.4.b, m_c merupakan vektor prototype yang terdekat dengan vektor input x . Sehingga m_c diperbarui (*update*) sebelum digunakan pada perulangan berikutnya. Besarnya *update* yang dialami vektor m_c tergantung pada nilai laju pelatihan α . Nilai laju pelatihan α dapat berupa konstanta ataupun variabel yang berubah secara monoton terhadap iterasi (Kohonen, 1995).

2.6.2 LVQ 2

Algoritma LVQ 2.1 digunakan untuk memperbaiki algoritma sebelumnya, LVQ 1. Perbaikan dilakukan pada percepatan pelatihan dengan melibatkan 2 vektor prototipe pada *update* vektor. Jika pada LVQ 1 vektor yang diperbarui adalah vektor yang paling dekat dengan vektor input, maka pada LVQ 2.1 vektor yang diperbarui adalah 2 vektor dari kelas berbeda yang merupakan vektor terdekat yang sesuai dengan kelas target pelatihan, dan vektor terdekat yang tidak sesuai dengan kelas target pelatihan. Vektor prototipe dengan kelas yang sesuai dengan target diperbarui mendekati vektor input. Sedangkan vektor prototipe dengan kelas yang tidak sesuai dengan target yang diperbarui menjauh dari vektor input. Proses perbaruan bobot untuk vektor-vektor prototipe pada LVQ 2.1 berdasarkan persamaan 2.5.

$$m_i(t+1) = m_i(t) + \alpha(t)[x(t) - m_i(t)] \quad (2.5.a)$$

$$m_j(t+1) = m_j(t) - \alpha(t)[x(t) - m_j(t)] \quad (2.5.b)$$

Vektor m_i dan m_j adalah dua vektor prototipe yang terdekat dengan vektor input $x(t)$, dimana m_i adalah vektor yang berada dalam kelas yang sama dengan kelas target, sedangkan m_j adalah vektor yang berada dalam kelas yang berbeda dengan kelas target (Kohonen, 1995).

2.6.3 Kondisi Berhenti

Seringkali dalam praktek terjadi terlalu banyak pembelajaran yang dilakukan. Hal ini tidak selamanya berpengaruh baik terhadap akurasi pengenalan.

Ketika perulangan yang terjadi pada pembelajaran mencapai suatu titik tertentu, maka akurasi yang didapatkan mencapai tingkat optimal. Apabila perulangan pembelajaran tetap dilanjutkan melewati titik optimal tersebut, maka akurasi pengenalan akan mengalami penurunan akurasi secara lambat. Untuk mendapatkan titik dimana akurasi mencapai tingkat optimal, sangat tergantung pada kasus dan arsitektur jaringan syaraf, oleh karena itu, titik optimal tersebut hanya dapat ditentukan dari hasil percobaan (Kohonen, 1995).

2.7 Association Rule

Association rule mining adalah suatu prosedur untuk mencari hubungan antar item dalam suatu *dataset* yang ditentukan (Han dan Kamber, 2000). Menurut Ulmer (2002), *association rule* meliputi dua tahap:

1. Mencari kombinasi yang paling sering terjadi dari suatu *itemset*.
2. Menetapkan kondisi dan hasil (untuk *conditional association rule*).

Dalam menentukan suatu *association rule*, terdapat suatu *interestingness measure* (ukuran kepercayaan) yang didapatkan dari hasil pengolahan data dengan perhitungan tertentu. Umumnya ada dua ukuran, yaitu (Budhi, 2005).:

1. *Support* merupakan suatu ukuran yang menunjukkan seberapa besar tingkat dominasi suatu item/itemset dari keseluruhan transaksi.
2. *Confidence* adalah suatu ukuran yang menunjukkan hubungan antar 2 item secara kondisional.

Kedua ukuran ini nantinya berguna dalam menentukan *interesting association rules*, yaitu untuk dibandingkan dengan batasan (*threshold*) yang ditentukan oleh user. Batasan tersebut umumnya terdiri dari *minimum support* dan *minimum confidence*. Jika terdapat *association rule* seperti $A \rightarrow B$, maka berdasarkan teori probabilitas, *support* dan *confidence* ditunjukkan oleh persamaan 2.2.

$$\text{Support} = P(A \cup B)$$

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

$P(A \cup B)$: probabilitas bahwa sebuah *record* mengandung A dan B.

$P(A|B)$: probabilitas kondisional, yang menunjukkan probabilitas bahwa sebuah *record* jika mengandung A maka mengandung B juga (Moradian dan Baarani, 2009).

Nilai *support* sebuah item diperoleh dengan persamaan 2.6. Sedangkan nilai confidence dari aturan $A \rightarrow B$ diperoleh dari persamaan 2.7

$$P(A \cup B) = \frac{\text{jumlah transaksi yang mengandung nilai } A}{\text{total transaksi}} \quad (2.6)$$

$$\text{Confidence} = P(A|B) = \frac{\text{jumlah transaksi yang mengandung nilai } A \text{ dan } B}{\text{jumlah transaksi yang mengandung } A} \quad (2.7)$$

2.8 Klasifikasi

Menurut Han dan Kamber (2000) klasifikasi adalah proses untuk menemukan suatu kumpulan model atau fungsi yang menggambarkan dan membedakan kelas data atau konsep, agar dapat menggunakan model tersebut untuk memprediksi kelas objek yang kelas labelnya tidak diketahui.

Klasifikasi merupakan suatu teknik yang dapat memberikan klasifikasi pada data baru dengan memanipulasi data yang telah diklasifikasi dan menggunakan hasilnya untuk memberikan sejumlah aturan. Aturan-aturan tersebut digunakan pada data-data baru untuk diklasifikasi. Teknik ini menggunakan *supervised induction*, yang memanfaatkan kumpulan pengujian dari *record* yang terkласifikasi untuk menentukan kelas data baru (Kusnawi, 2007). Menurut Pramudiono (2003), proses klasifikasi biasanya dibagi menjadi dua fase, yaitu:

1. Learning

Pada fase ini sebagian data yang telah diketahui kelas datanya diumpulkan untuk membentuk model perkiraan.

2. Test

Pada fase ini model yang sudah terbentuk diuji dengan sebagian data lainnya untuk mengetahui akurasi dari model tersebut. Bila akurasinya mencukupi, model ini dapat dipakai untuk prediksi kelas data yang belum diketahui.

2.9 Evaluasi

Evaluasi dilakukan untuk mengetahui tingkat akurasi dari hasil klasifikasi, dengan cara menghitung jumlah *record* uji yang kelasnya diprediksi secara tepat (akurat). Menurut Sarkar dan Leong (2000), persentase akurasi diperoleh dengan persamaan 2.8

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Jumlah total prediksi}} \times 100\% \quad (2.8)$$

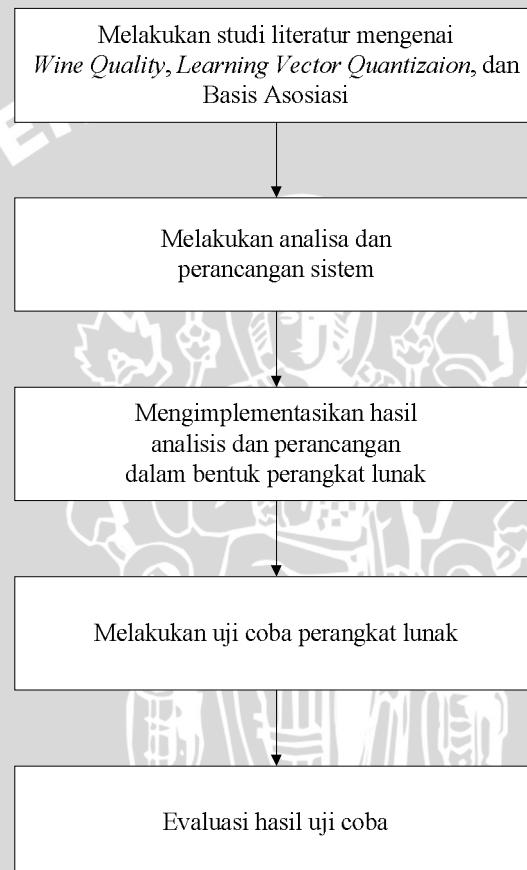
Jumlah prediksi benar adalah jumlah *record* data uji yang diprediksi kelasnya menggunakan metode klasifikasi dan hasilnya sama dengan kelas sebenarnya. Sedangkan jumlah total prediksi adalah jumlah keseluruhan *record* yang diprediksi kelasnya (seluruh data uji).

Pada evaluasi digunakan *10-fold cross validation*. Metode ini merupakan merupakan metode *cross validation* yang paling sering digunakan pada data mining. Cross validation merupakan metode statistik untuk evaluasi atau membandingkan algoritma pembelajaran, yang dilakukan dengan membagi data menjadi dua bagian : satu bagian digunakan sebagai model pembelajaran dan yang lain digunakan untuk memvalidasi model (Refaeilzadeh, 2008). Pada metode *10-fold cross validation*, *dataset* dibagi menjadi 10 bagian. 1/10 dari dataset sebagai data uji sedangkan sisanya atau 9/10 dari *dataset* digunakan sebagai data latih. Pengujian dilakukan pada 1/10 bagian yang lain, sehingga terdapat total 10 pengujian. Akurasi merupakan nilai akurasi rata-rata dari 10 pengujian tersebut. Metode klasifikasi berusaha untuk mencari model yang memiliki tingkat akurasi yang tinggi ketika model tersebut diterapkan pada data uji.

BAB III

METODOLOGI DAN PERANCANGAN SISTEM

Pada bab ini menjelaskan langkah-langkah yang akan ditempuh dalam menyusun penelitian. Tahapan penelitian ini dirancang untuk membangun sistem klasifikasi yang dapat digunakan dalam pengklasifikasian kualitas *wine*.



Gambar 3.1 Langkah-langkah Penelitian

Berdasarkan Gambar 3.1, langkah-langkah yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Melakukan studi literatur mengenai algoritma *Learning Vector Quantization* (LVQ), *association rule* berbasis asosiasi, dataset mengenai

wine quality serta literatur lain yang berkaitan dengan metode yang digunakan.

2. Melakukan analisa dan perancangan sistem.
3. Mengimplementasikan hasil analisis dan perancangan yang telah dilakukan dalam bentuk perangkat lunak untuk pengklasifikasian dataset yang telah ditentukan menggunakan LVQ berbasis asosiasi.
4. Melakukan uji coba terhadap perangkat lunak.
5. Mengevaluasi hasil yang diperoleh dari uji coba perangkat lunak.

5.1 Studi Literatur

Dalam penelitian ini dibutuhkan studi literatur untuk merealisasikan tujuan dan penyelesaian masalah. Teori-teori berkaitan dengan *association rule* dan algoritma *learning vector quantization* digunakan sebagai dasar penelitian yang didapat dari buku, jurnal dan *browsing* dari internet. Dari data yang diperoleh akan diolah sehingga dapat digunakan untuk analisis. Setelah dilakukan analisis maka dapat diimplementasikan ke dalam aplikasi.

5.2 Data Penelitian

Untuk mengetahui kinerja dari pengklasifikasian menggunakan metode *Learning Vector Quantization* berbasis asosiasi dibutuhkan *dataset wine quality* yang telah tersedia di <http://archive.ics.uci.edu/ml/datasets/Wine+Quality> yang diterbitkan pada tahun 2009. UCI *Machine Learning Repository* merupakan penyedia dataset untuk penelitian berbasis web.

Dari dataset yang diambil dari UCI *Machine Learning Repository*, terdapat 1599 *instances* untuk *dataset red wine* dan 4898 *instances* untuk *dataset white wine*. Terdapat 11 atribut dan 1 atribut kelas pada dataset tersebut, berikut ini atribut yang terdapat pada *dataset wine quality*,

- 1 - *fixed acidity*
- 2 - *volatile acidity*
- 3 - *citric acid*
- 4 - *residual sugar*
- 5 - *chlorides*

6 - free sulfur dioxide

7 - total sulfur dioxide

8 - density

9 - pH

10 - sulphates

11 - alcohol

12 - quality / class

Atribut ke-1 sampai dengan ke-11 merupakan data senyawa kimia yang terkandung di dalam *wine*. Sedangkan atribut ke-12 merupakan atribut kelas *wine* berdasarkan *data sensory*. Kelas pada *dataset wine quality* mempunyai rentang nilai dari kelas 1 (sangat buruk sekali) sampai dengan kelas 10 (sempurna). Dari keseluruhan atribut di atas memiliki nilai *real*.

Rincian distribusi kelas pada *dataset red wine quality* berdasarkan tes *sensory* sebagai berikut,

- Kualitas 3 sebanyak 10 data
- Kualitas 4 sebanyak 53 data
- Kualitas 5 sebanyak 681 data
- Kualitas 6 sebanyak 638 data
- Kualitas 7 sebanyak 199 data
- Kualitas 8 sebanyak 18 data

Sedangkan distribusi kelas pada *dataset white wine quality* berdasarkan tes *sensory* sebagai berikut,

- Kualitas 3 sebanyak 20 data
- Kualitas 4 sebanyak 163 data
- Kualitas 5 sebanyak 1457 data
- Kualitas 6 sebanyak 2198 data
- Kualitas 7 sebanyak 880 data
- Kualitas 8 sebanyak 175 data
- Kualitas 9 sebanyak 5 data

5.3 Analisa Sistem

5.3.1 Deskripsi Sistem

Sistem yang dibuat merupakan perangkat lunak yang dapat mengimplementasikan algoritma *Learning Vector Quantization* Berbasis Asosiasi untuk pengklasifikasian kualitas minuman anggur. Aturan asosiasi digunakan untuk mencari perulangan pola data pada setiap atribut dengan tujuan pemberian bobot pada setiap atibutnya. Aturan asosiasi digunakan pada dataset yang bejumlah besar dan memiliki atribut yang banyak sehingga nilai bobot akan membantu dalam pemilihan atribut mana yang berpengaruh terhadap pola dataset maupun tidak. Perangkat lunak ini akan menguji keakuratan hasil pengklasifikasian terhadap *dataset wine quality* dibandingkan dengan pengklasifikasian berdasarkan uji *sensory*.

Parameter yang digunakan dalam pengklasifikasian ini berkaitan dengan *learning rate*, epoh maksimum, nilai *error* maksimum, nilai minimum group *support* dan minimum group *confidence* yang berpengaruh terhadap hasil akurasi.

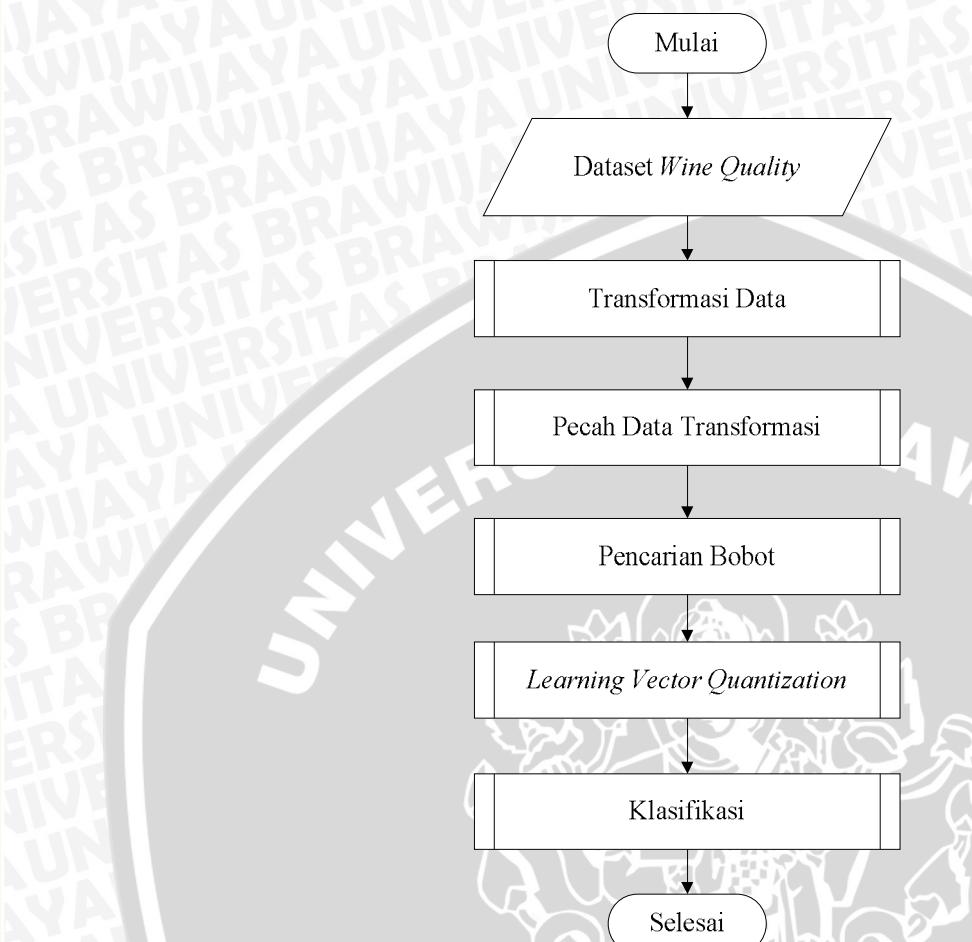
5.3.2 Batasan Sistem

Sistem yang dibuat memiliki keterbatasan sebagai berikut:

1. *Dataset* asli (*raw*) diambil dari *database* terlebih dahulu dan dijadikan array sebelum diproses lebih lanjut.
2. Sistem tidak menangani permasalahan *missing value* dan *outliers*.
3. *Learning rate*, epoh maksimum, nilai eror maksimum, nilai minimum group *support* dan minimum group *confidence* dimasukkan secara manual oleh *user*.

5.4 Perancangan Proses

Subbab ini menjelaskan proses dari klasifikasi menggunakan algoritma LVQ berbasis asosiasi secara keseluruhan.



Gambar 3.2 Alur Proses Sistem

Berdasarkan Gambar 3.2, proses pada sistem meliputi empat proses utama, yaitu:

1. Transformasi Data

Proses transformasi data mulai dari konversi dataset menjadi bentuk array hingga proses normalisasi yang dilakukan terhadap data secara keseluruhan.

2. Pecah Data Transformasi

Merupakan proses pemisahan antara data latih dan data uji yang berasal dari data secara keseluruhan. Dalam proses pemisahan data, ditambahkan pencarian centroid awal yang akan digunakan sebagai acuan di proses *learning vector quantization*.

3. Proses Pencarian Bobot

Merupakan proses untuk menentukan bobot pada setiap atribut menggunakan aturan asosiasi terhadap data latih sebelum data latih diproses lebih lanjut,

4. Learning Vector Quantization

Merupakan proses pembelajaran dari *learning vector quantization* dimana diperlukan centroid awal sebagai acuan yang diambil dari data latih, selanjutnya akan mengalami proses perubahan posisi data centroid yang sampai batas epoh tertentu.

5. Klasifikasi

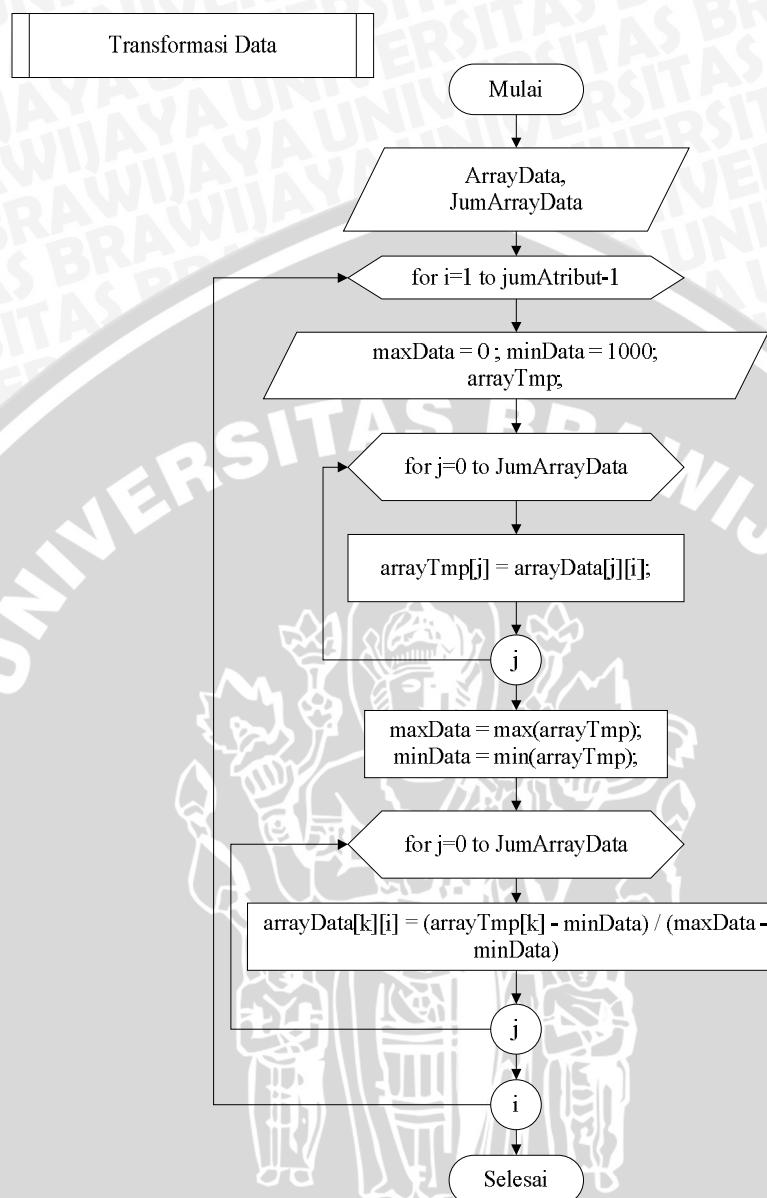
Merupakan proses pengklasifikasian berdasarkan jarak antara data uji dengan centroid terdekat

5.4.1 Transformasi Data

Proses transformasi data yang berupa normalisasi data latih maupun data uji dilakukan dengan langkah-langkah berikut,

1. Inputan berupa array data yang telah dikonversi dari database
2. Iterasi dimulai dari 1 hingga jumlah atribut pada data
3. *Set maxData = 0, minData = 1000, arrayTmp;*
4. Dilakukan iterasi pada seluruh data beratribut sama untuk mencari nilai maksimum dan minimunnya.
5. Dilakukan iterasi dari indeks 0 sampai dengan jumlah data
6. Didapatkan nilai baru pada tiap data
7. Ulangi langkah ke-5 sampai batas jumlah data
8. Ulangi langkah ke-2 sampai batas jumlah atribut

Flowchart proses transformasi data ditampilkan pada gambar 3.4



Gambar 3.3 Flowchart Normalisasi Data

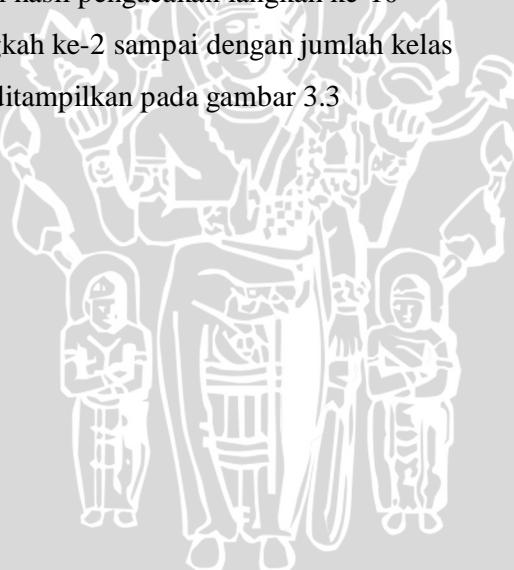
5.4.2 Pecah Data Transformasi

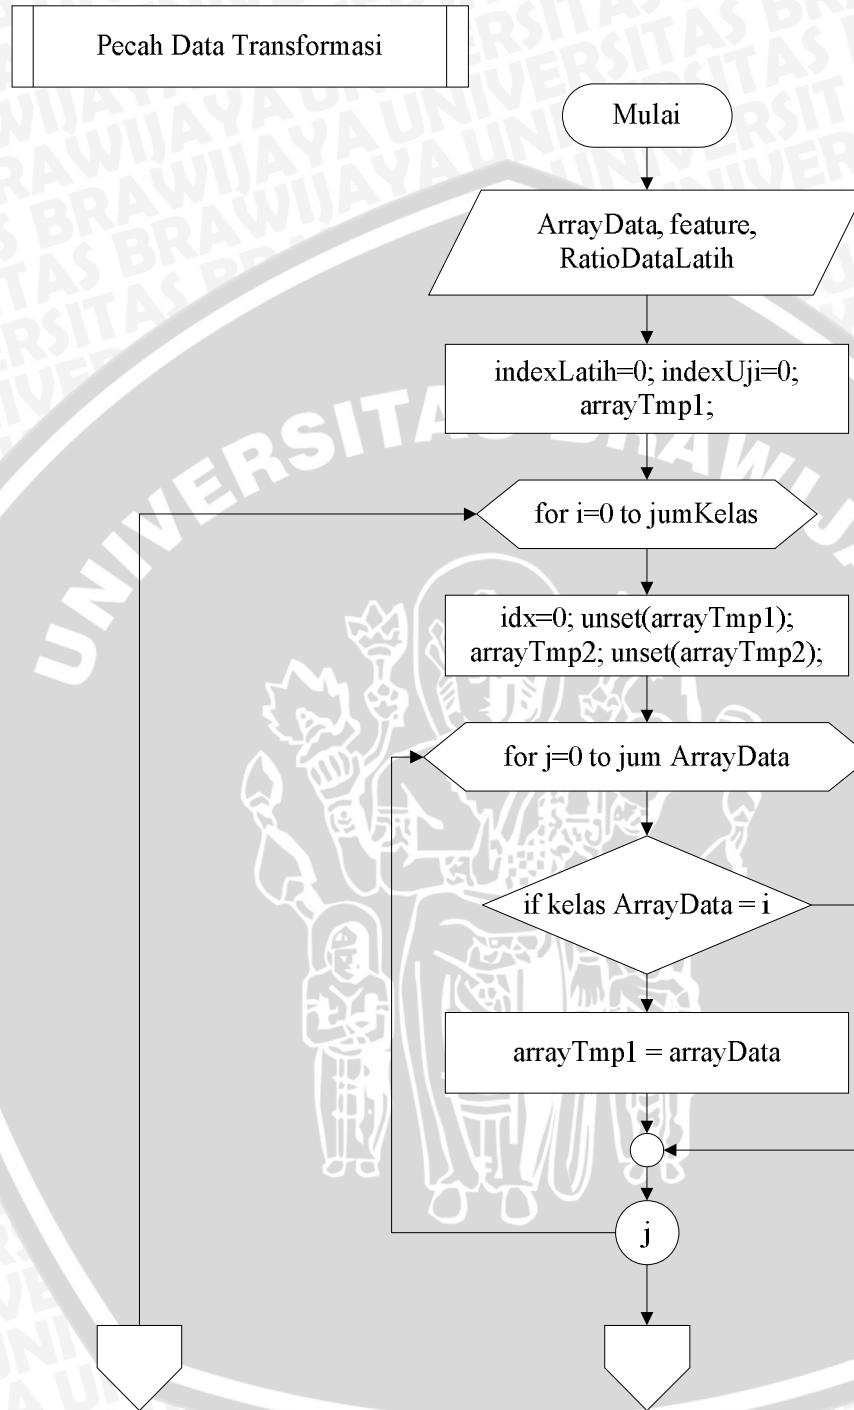
Proses konversi data dan pecah data dilakukan dengan langkah-langkah berikut,

1. Inputan berupa array data yang telah dinormalisasi
2. Dilakukan interasi sebanyak jumlah kelas
3. Dilakukan iterasi sebanyak jumlah data

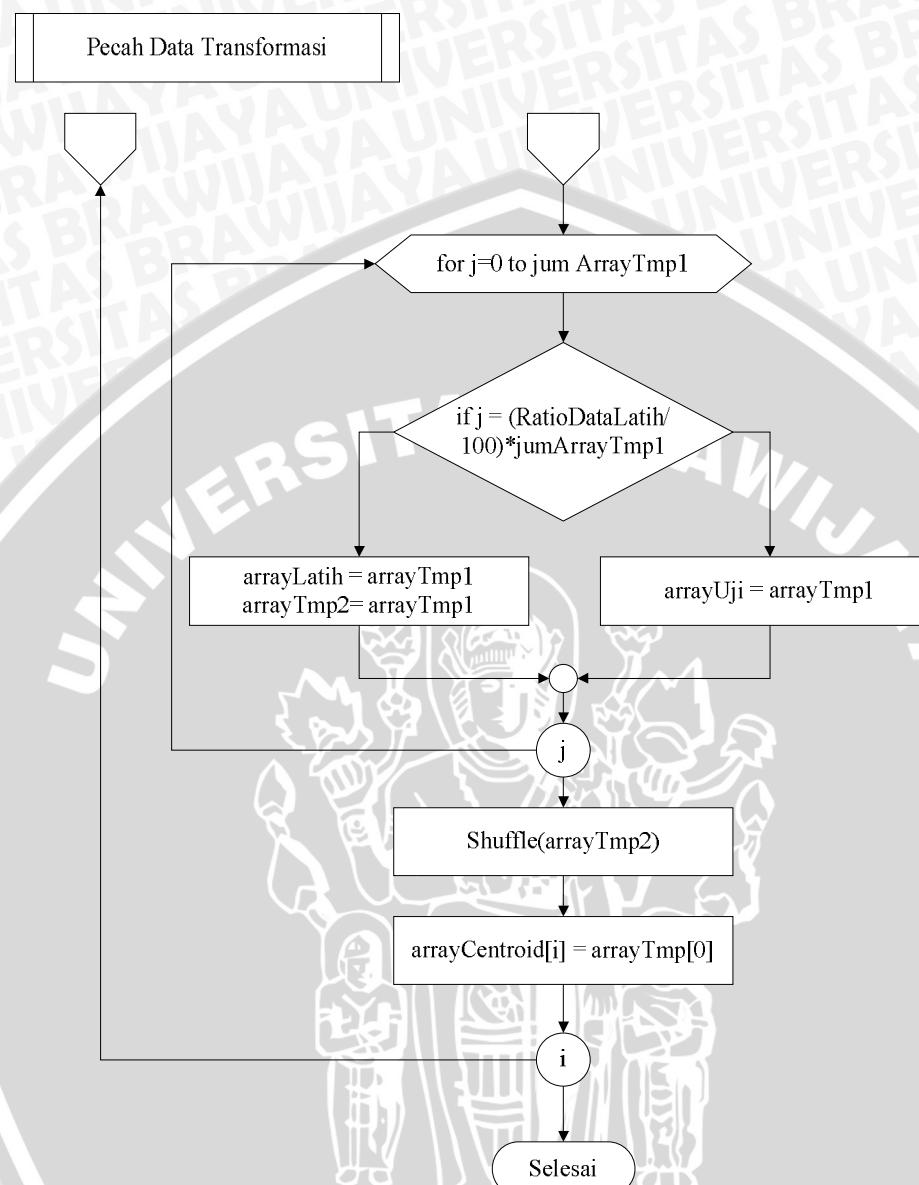
4. Dilakukan pengecekan kelas antara indeks pada langkah ke-2 dengan kelas data.
5. Inisialisasi arrayTmp1 sama dengan array data
6. Ulangi langkah k-4 sampai dengan jumlah data
7. Dilakukan iterasi dengan jumlah data latih yang ada pada kelas tertentu sesuai dengan langkah ke-2
8. Dilakukan pemisahan antara data latih dengan data uji pada kelas data yang sama dengan perbandingan yang telah dimasukkan+
9. Ulangi langkah k-7 sampai dengan jumlah data
10. Dilakukan pengacakan array pada data latih dengan kelas tertentu sesuai dengan indeks pada langkah ke-2
11. ArrayCentroid awal dengan indek kelas sesuai dengan langkah ke-2 diambil dari hasil pengacakan langkah ke-10
12. Ulangi langkah ke-2 sampai dengan jumlah kelas

Flowchart pecah data ditampilkan pada gambar 3.3





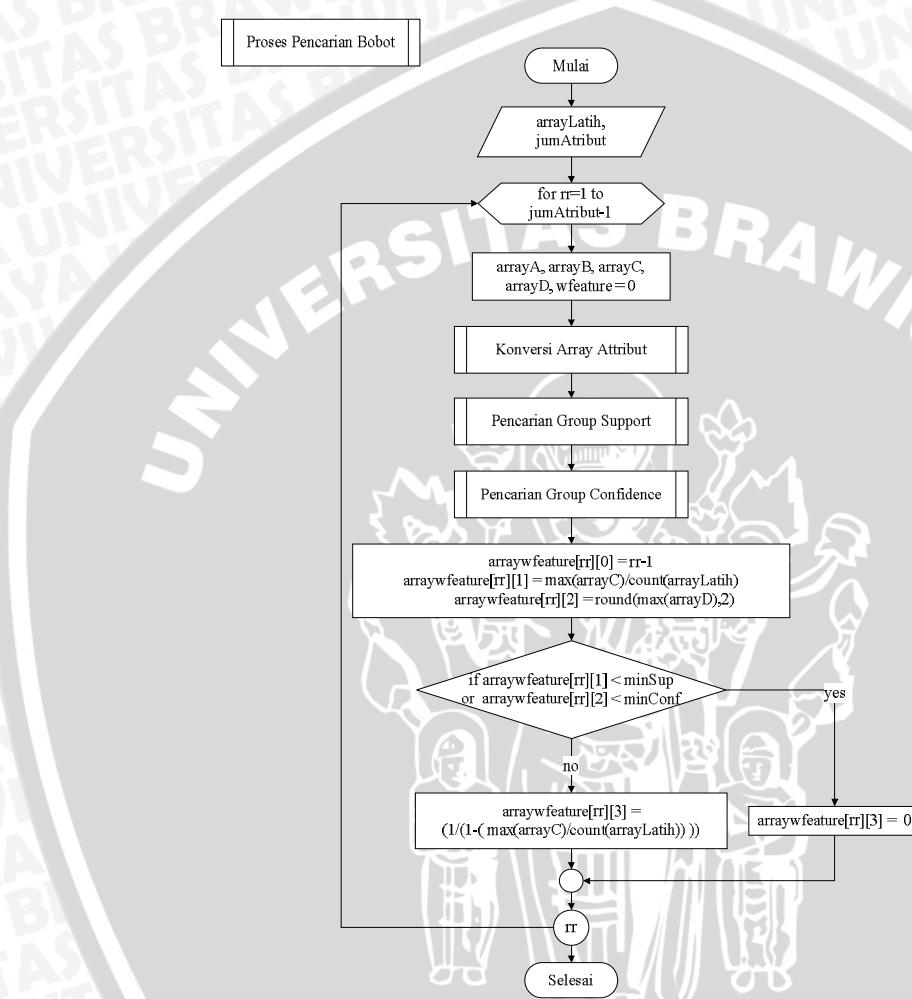
Gambar 3.4 Flowchart Pecah Data



Gambar 3.5 Flowchart Pecah Data

5.4.3 Proses Pencarian Bobot

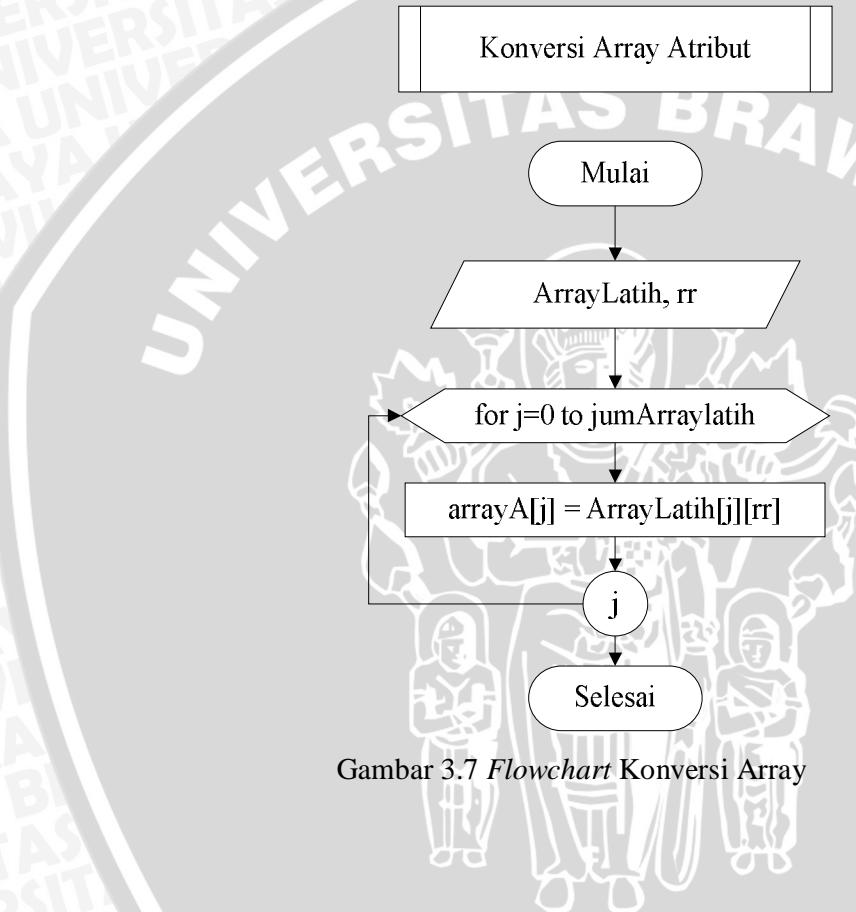
Proses pencarian bobot pada tiap atribut pada data dilakukan dengan langkah-langkah berikut,



Gambar 3.6 Flowchart Proses Pencarian Bobot

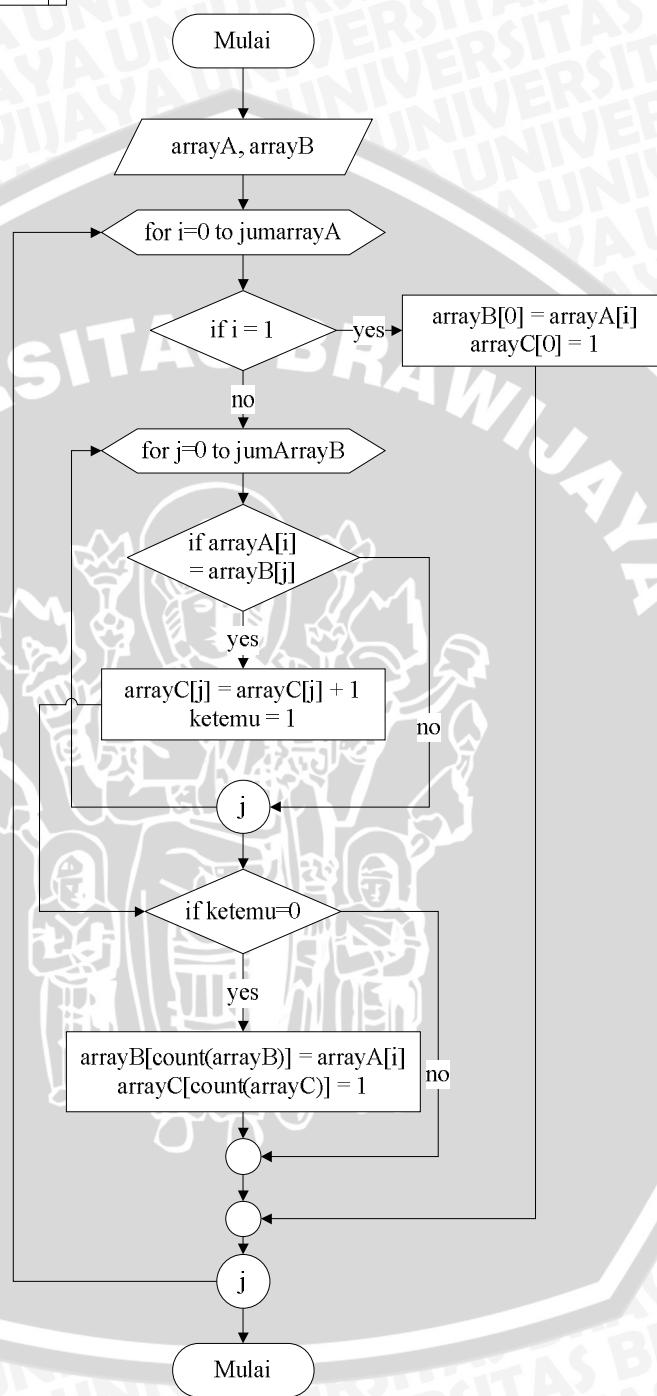
1. Inputan berupa array latih yang sudah ternormalisasi
2. Iterasi dilakukan sejumlah atribut data, dimulai dengan indeks 1
3. Dilakukan konversi ke dalam bentuk arrayTmp tiap data pada atribut ke-i
4. Dilakukan proses pencarian nilai group *support* pada atribut ke-i
5. Dilakukan proses pencarian nilai group *confidence* pada atribut ke-i

6. Jika nilai group *support* lebih kecil dari minSup atau nilai group *confidence* lebih kecil dari minConf, maka bobot pada atribut ke-i menjadi 0. Jika tidak, maka nilai bobot dihitung dengan persamaan $w[i] = 1/(1-\text{nilai group support})$.
7. Ulangi langkah ke 3 sesuai dengan jumlah atribut yang ada.

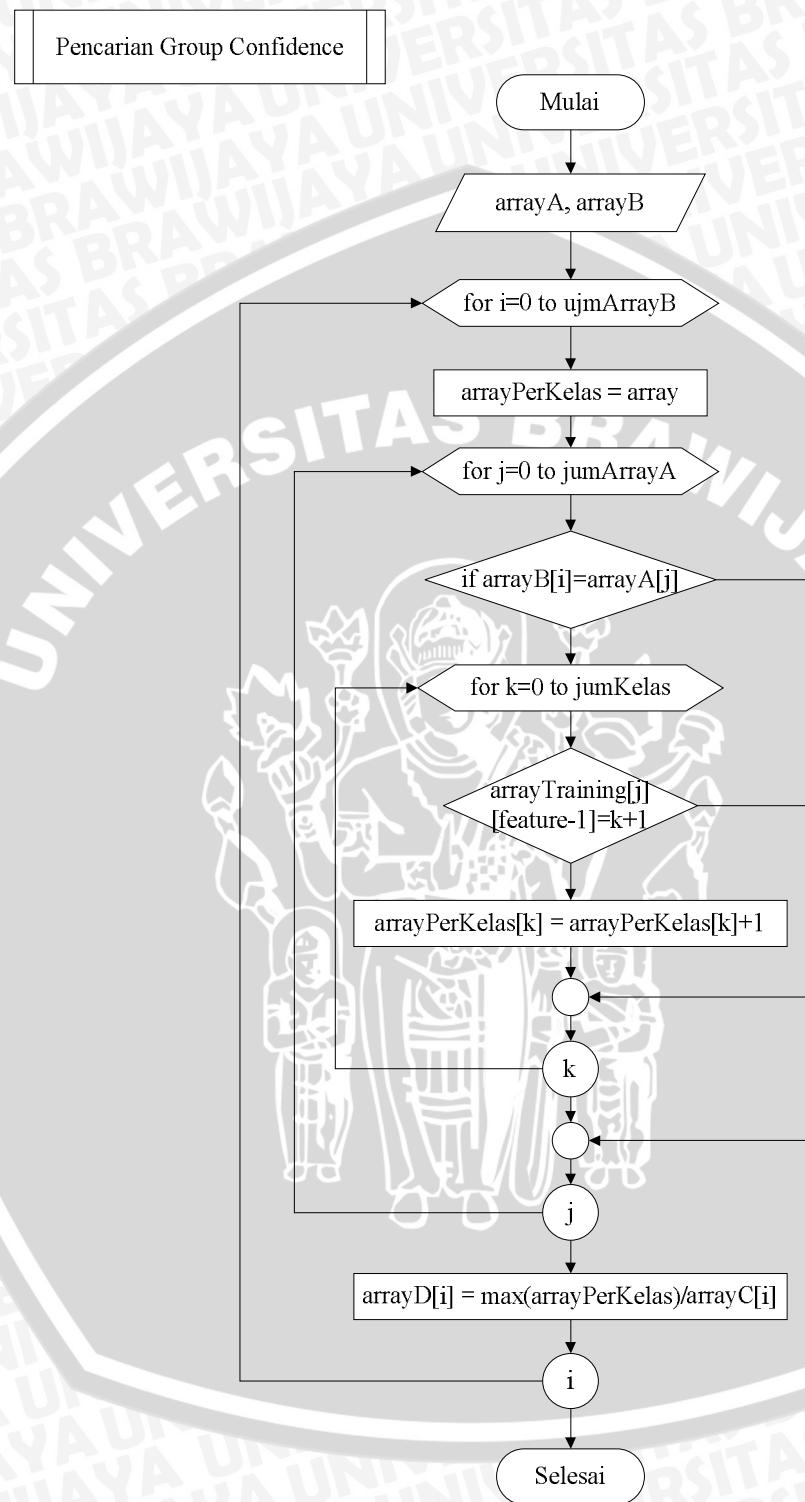


Gambar 3.7 Flowchart Konversi Array

Pencarian Group Support



Gambar 3.8 Flowchart Pencarian Group Support

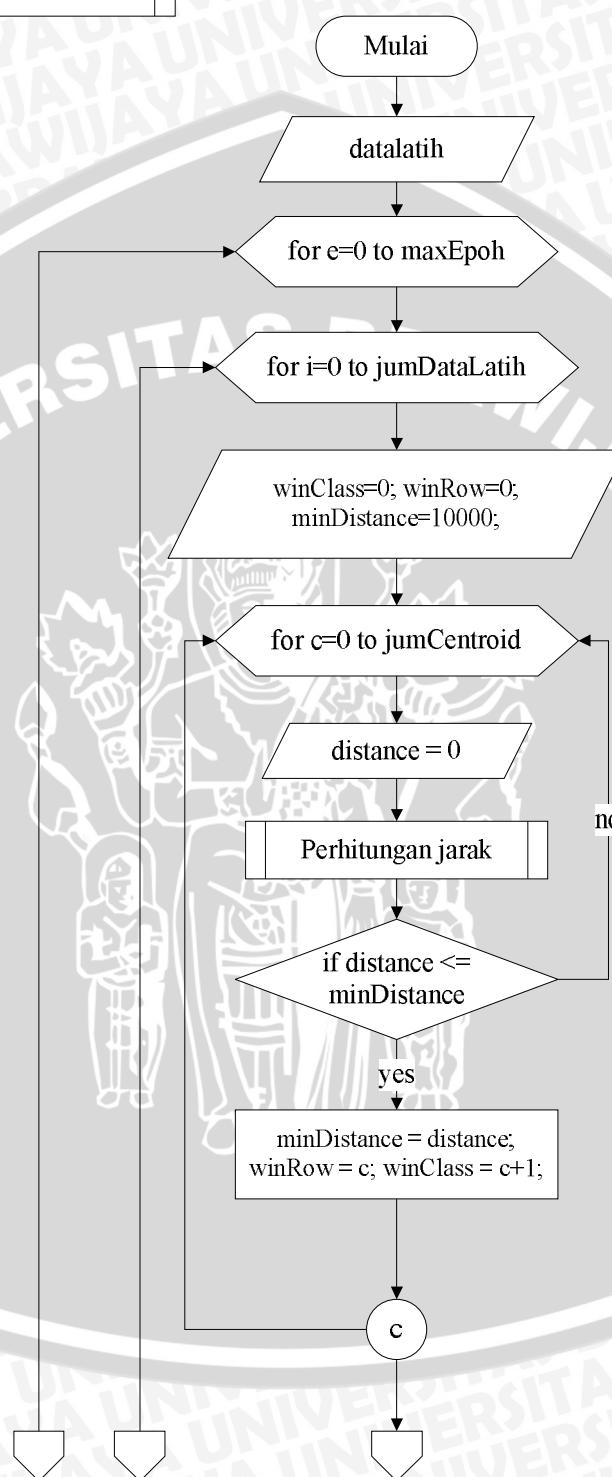


Gambar 3.9 Flowchart Pencarian Group *Confidence*

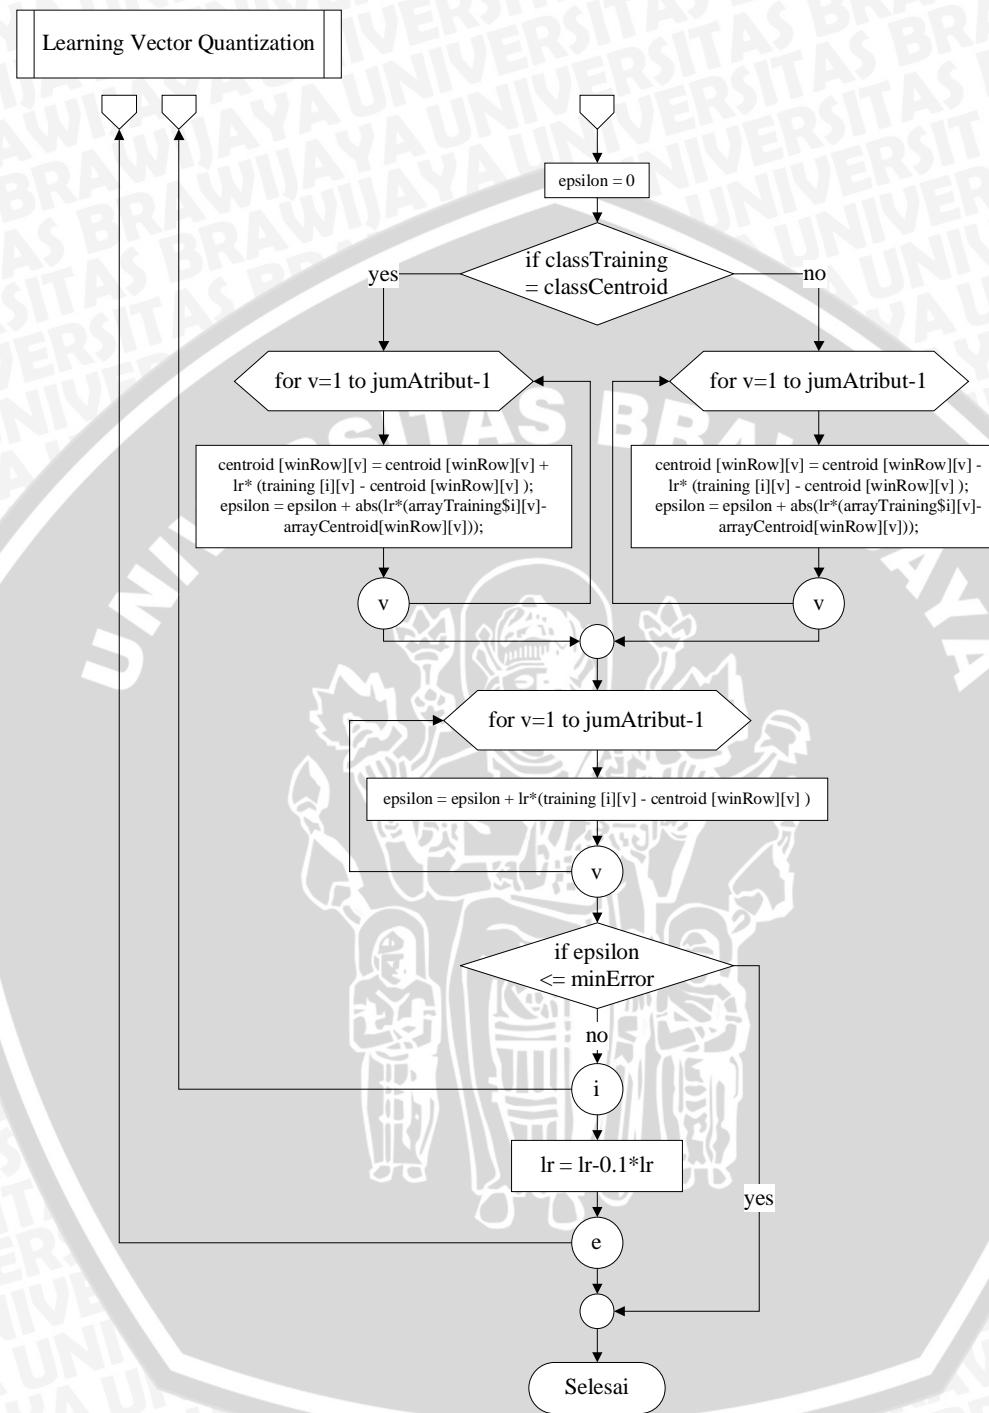
5.4.4 Proses Learning Vector Quantization

Proses *Learning Vector Quantization* terhadap data dilakukan dengan langkah-langkah berikut,

1. Input berupa data latih yang sudah ternormalisasi
2. Dilakukan iterasi sebanyak maxEpoh dengan indeks e.
3. Dilakukan iterasi sebanyak data latih dengan indeks i.
4. Dilakukan pencarian jarak terdekat antara data latih ke-i dengan seluruh data centroid yang ada.
5. Dilakukan pengecekan antara kelas data latih dengan data centroid terdekat, jika memiliki kelas yang sama, maka data centroid terdekat akan bergeser mendekati data latih ke-i. Dan jika tidak, data centroid akan bergeser menjauhi data latih ke-i.
6. Dilakukan perhitungan pencarian nilai epsilonnya.
7. Jika nilai epsilon < minError, maka iterasi berhenti.
8. Kembali ke langkah 3.
9. Dilakukan perhitungan penurunan nilai learning rate.
10. Kembali ke langkah 2.
11. Data centroid telah terupdate.

Learning Vector Quantization

Gambar 3.10 Flowchart Learning Vector Quantization

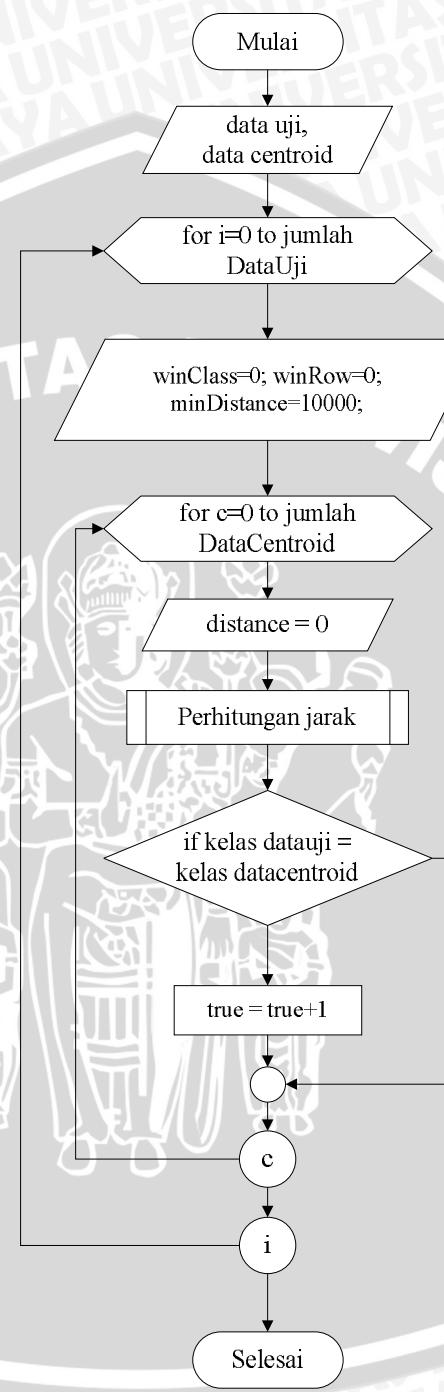


Gambar 3.11 Flowchart Learning Vector Quantization

5.4.5 Proses Klasifikasi

Proses Klasifikasi terhadap data uji dilakukan dengan langkah-langkah berikut,

1. Input berupa data uji yang sudah ternormalisasi.
2. Set $true=0$.
3. Dilakukan iterasi sebanyak data uji dengan indeks i.
4. Set $minDistance=1000$
5. Dilakukan iterasi sebanyak data centroid dengan indeks c.
6. Set $distance=0$
7. Dilakukan pencarian jarak antara data uji ke-i ke data centroid ke-c.
8. Jika jarak kurang dari $minDistance$, maka $minDistance$ sama dengan jarak data uji ke-i terhadap data centroid ke-c.
9. Kembali ke langkah 5 sampai dengan banyak data centroid.
10. Jika kelas pada data uji sama dengan kelas pada data centroid dengan jarak terdekat, maka nilai $true$ bertambah satu, jika tidak nilai true tetap.
11. Kembali ke langkah 3 sampai dengan banyak data uji.

Klasifikasi

Gambar 3.12 Flowchart Klasifikasi

5.5 Perhitungan Manual

3.5.1 Dataset

Berikut ini tabel 3.1 merupakan *dataset* yang telah diambil secara acak dari *dataset red wine quality*, atribut yang diambil dalam perhitungan manual ini adalah atribut *alcohol*, *sulphates*, *pH*, *fixed acidity*, dan *volatile acidity*. Diambil sebanyak 21 data dengan 20 data yang akan dipakai sebagai data latih, dan data ke-21 akan digunakan sebagai data uji yang akan diklasifikasikan pada kelas tertentu. Kelas kualitas yang digunakan hanya kelas 3 sampai kelas 6.

Tabel 3.1 Data Raw Perhitungan Manual

no	alcohol	sulphates	ph	fixed acidity	volatile acidity	class
1	9.7	0.67	3.32	10.1	0.31	4
2	11.3	0.67	3.42	6.8	0.67	4
3	10.2	0.49	3.21	8	0.45	4
4	9.4	0.46	3.3	7.9	0.6	3
5	9.5	0.53	3.44	8	0.71	3
6	9.5	0.55	3.13	10	0.58	3
7	12	0.7	3.23	8.9	0.35	5
8	10	0.56	3.33	7.8	0.53	4
9	11.3	0.73	3.23	7.2	0.37	5
10	10.2	0.7	3.13	11.4	0.46	3
11	10.7	0.55	3.52	6.8	0.785	4
12	13	0.77	3.18	13.5	0.53	3
13	11.2	0.74	3.26	10.4	0.33	5
14	11.1	0.58	3.23	9.1	0.21	5
15	11.3	0.6	3.38	7	0.69	4
16	9.2	0.46	3.26	7.8	0.87	3
17	11	0.54	3.38	6.1	0.6	3
18	9.7	0.59	3.26	7.7	0.54	3
19	11.5	0.63	3.45	6.9	0.74	4
20	9.8	0.66	3.59	6.4	0.64	3
21	9.5	0.58	3.4	7.2	0.35	?

3.5.2 Transformasi Data

Dalam proses transformasi data normalisasi, dilakukan terlebih dahulu nilai maksimum dan nilai minimum pada tiap-tiap atribut. Berikut ini contoh normalisasi pada atribut pertama (*fixed acidity*) dan pada data yang pertama.

- Data (V) = 9.7
- Nilai maximum atribut *fixed acidity* (max) = 13
- Nilai minimum atribut *fixed acidity* (min) = 9.2

Normalisasi pada data pertama pada atribut *fixed acidity* dilakukan seperti langkah di bawah ini,

$$V' = \frac{(V-\text{min})}{(\text{max}-\text{min})} = \frac{(9.7-9.2)}{(13-9.2)} = 0.13$$

Perhitungan normalisasi juga dilakukan untuk semua data pada seluruh atribut. Hasil perhitungan normalisasi terdapat pada tabel 3.2,

Tabel 3.2 Data Hasil Transformasi Perhitungan Manual

no	alcohol	sulphates	ph	fixed acidity	volatile acidity	class
1	0.13	0.68	0.41	0.54	0.15	4
2	0.55	0.68	0.63	0.09	0.7	4
3	0.26	0.1	0.17	0.26	0.36	4
4	0.05	0	0.37	0.24	0.59	3
5	0.08	0.23	0.67	0.26	0.76	3
6	0.08	0.29	0	0.53	0.56	3
7	0.74	0.77	0.22	0.38	0.21	5
8	0.21	0.32	0.43	0.23	0.48	4
9	0.55	0.87	0.22	0.15	0.24	5
10	0.26	0.77	0	0.72	0.38	3
11	0.39	0.29	0.85	0.09	0.87	4
12	1	1	0.11	1	0.48	3
13	0.53	0.9	0.28	0.58	0.18	5
14	0.5	0.39	0.22	0.41	0	5
15	0.55	0.45	0.54	0.12	0.73	4
16	0	0	0.28	0.23	1	3
17	0.47	0.26	0.54	0	0.59	3
18	0.13	0.42	0.28	0.22	0.5	3
19	0.61	0.55	0.7	0.11	0.8	4
20	0.16	0.65	1	0.04	0.65	3
21	0.08	0.39	0.59	0.15	0.21	?

3.5.3 Pencarian Bobot Pada Tiap Atribut

- **Group Support**

Sebelum menentukan nilai *group support*, terlebih dahulu dilakukan perhitungan *support* pada tiap *rule* menggunakan persamaan 2.3. berikut adalah contoh perhitungan *group support* untuk atribut pertama (*alcohol*).

$$\text{Support}(V) = \frac{\text{Jumlah data bernilai } V}{\text{Jumlah data}}$$

$$\text{Support}(0) = \frac{1}{20} = 0.05$$

$$\text{Support}(0.39) = \frac{1}{20} = 0.05$$

$$\text{Support}(0.05) = \frac{1}{20} = 0.05$$

$$\text{Support}(0.47) = \frac{1}{20} = 0.05$$

$$\text{Support}(0.08) = \frac{2}{20} = 0.1$$

$$\text{Support}(0.5) = \frac{1}{20} = 0.05$$

$$\text{Support}(0.13) = \frac{2}{20} = 0.1$$

$$\text{Support}(0.53) = \frac{1}{20} = 0.05$$

$$\text{Support}(0.16) = \frac{1}{20} = 0.05$$

$$\text{Support}(0.55) = \frac{3}{20} = 0.15$$

$$\text{Support}(0.21) = \frac{1}{20} = 0.05$$

$$\text{Support}(0.61) = \frac{1}{20} = 0.05$$

$$\text{Support}(0.26) = \frac{2}{20} = 0.1$$

$$\text{Support}(0.74) = \frac{1}{20} = 0.05$$

$$\text{Support}(1) = \frac{1}{20} = 0.05$$

Nilai *group support* adalah nilai yang terbesar dari seluruh nilai *support* yang ada, yaitu 0.15.

- **Group Confidence**

Sebelum menentukan nilai *group confidence*, terlebih dahulu dilakukan perhitungan nilai *confidence* pada tiap *rule* menggunakan persamaan 2.4. berikut adalah contoh perhitungan *group confidence* untuk atribut pertama (*alcohol*).

$$\text{Confidence}(V) = (V \rightarrow C) = \frac{\text{Jumlah data bernilai } V \text{ dan kelas } C}{\text{Jumlah data bernilai } V}$$

$$\text{Confidence}(0) = (0 \rightarrow 3) = \frac{\text{Jumlah data bernilai } 0 \text{ dan kelas } 3}{\text{Jumlah data bernilai } 0} = \frac{1}{1} = 1$$

$$\text{Confidence}(0.05) = (0.05 \rightarrow 3) = \frac{\text{Jumlah data bernilai } 0.05 \text{ dan kelas } 3}{\text{Jumlah data bernilai } 0.05} = \frac{1}{1} = 1$$

$$\text{Confidence}(0.08) = (0.08 \rightarrow 3) = \frac{\text{Jumlah data bernilai } 0.08 \text{ dan kelas } 3}{\text{Jumlah data bernilai } 0.08} = \frac{2}{2} = 1$$

$$\text{Confidence}(0.13) = (0.13 \rightarrow 3) = \frac{\text{Jumlah data bernilai } 0.13 \text{ dan kelas } 3}{\text{Jumlah data bernilai } 0.13} = \frac{1}{2} = 0.5$$

$$\text{Confidence}(0.13) = (0.13 \rightarrow 4) = \frac{\text{Jumlah data bernilai } 0.13 \text{ dan kelas } 4}{\text{Jumlah data bernilai } 0.13} = \frac{1}{2} = 0.5$$

$$\text{Confidence}(0.16) = (0.16 \rightarrow 3) = \frac{\text{Jumlah data bernilai } 0.16 \text{ dan kelas } 3}{\text{Jumlah data bernilai } 0.16} = \frac{1}{1} = 1$$

$$\text{Confidence}(0.21) = (0.21 \rightarrow 4) = \frac{\text{Jumlah data bernilai } 0.21 \text{ dan kelas } 4}{\text{Jumlah data bernilai } 0.21} = \frac{1}{1} = 1$$

$$\text{Confidence}(0.26) = (0.26 \rightarrow 3) = \frac{\text{Jumlah data bernilai } 0.26 \text{ dan kelas } 3}{\text{Jumlah data bernilai } 0.26} = \frac{1}{2} = 0.5$$

$$\text{Confidence}(0.26) = (0.26 \rightarrow 4) = \frac{\text{Jumlah data bernilai } 0.26 \text{ dan kelas } 4}{\text{Jumlah data bernilai } 0.26} = \frac{1}{2} = 0.5$$

$$\text{Confidence}(0.39) = (0.39 \rightarrow 4) = \frac{\text{Jumlah data bernilai } 0.39 \text{ dan kelas } 4}{\text{Jumlah data bernilai } 0.39} = \frac{1}{1} = 1$$

$$\text{Confidence}(0.47) = (0.47 \rightarrow 3) = \frac{\text{Jumlah data bernilai } 0.47 \text{ dan kelas } 3}{\text{Jumlah data bernilai } 0.47} = \frac{1}{1} = 1$$

$$\text{Confidence}(0.5) = (0.5 \rightarrow 5) = \frac{\text{Jumlah data bernilai } 0.5 \text{ dan kelas } 5}{\text{Jumlah data bernilai } 0.5} = \frac{1}{1} = 1$$

$$\text{Confidence}(0.53) = (0.53 \rightarrow 5) = \frac{\text{Jumlah data bernilai } 0.53 \text{ dan kelas } 5}{\text{Jumlah data bernilai } 0.53} = \frac{1}{1} = 1$$

$$\text{Confidence}(0.55) = (0.55 \rightarrow 4) = \frac{\text{Jumlah data bernilai } 0.55 \text{ dan kelas } 4}{\text{Jumlah data bernilai } 0.55} = \frac{2}{3} = 0.67$$

$$\text{Confidence}(0.55) = (0.55 \rightarrow 5) = \frac{\text{Jumlah data bernilai } 0.55 \text{ dan kelas } 5}{\text{Jumlah data bernilai } 0.55} = \frac{1}{3} = 0.33$$

$$\text{Confidence}(0.61) = (0.61 \rightarrow 4) = \frac{\text{Jumlah data bernilai } 0.61 \text{ dan kelas } 4}{\text{Jumlah data bernilai } 0.61} = \frac{1}{1} = 1$$

$$\text{Confidence}(0.74) = (0.74 \rightarrow 5) = \frac{\text{Jumlah data bernilai } 0.74 \text{ dan kelas } 5}{\text{Jumlah data bernilai } 0.74} = \frac{1}{1} = 1$$

$$\text{Confidence}(1) = (1 \rightarrow 3) = \frac{\text{Jumlah data bernilai } 1 \text{ dan kelas } 3}{\text{Jumlah data bernilai } 1} = \frac{1}{1} = 1$$

Nilai *group confidence* adalah nilai yang terbesar dari seluruh nilai *confidence* yang ada, yaitu 1.

Dengan cara yang sama, perhitungan nilai *support* dan *confidence* dilakukan pada semua atribut, dan hasilnya terdapat pada tabel 3.3.

Tabel 3.3 Tabel *Group Support* dan *Group Confidence*

	Group Support	Group Confidence
alcohol	0.15	1
sulphates	0.1	1
pH	0.15	1
fixed acidity	0.1	1
volatile acidity	0.1	1

- **Menghitung bobot tiap atribut**

Dalam penghitungan bobot setiap atribut, terlebih dahulu ditentukan nilai *group support* minimumnya dan *group confidence* minimumnya, jika nilai *group support* lebih kecil dari nilai *group support* minimum ($\text{gSup} < \text{minSup}$) atau nilai *group confidence* lebih kecil dari nilai *group confidence* minimum ($\text{gConf} < \text{minConf}$), maka bobot atribut bernilai 0. Jika tidak, maka dilakukan

perhitungan seperti pada perhitungan bobot atribut pertama (*alcohol*) sebagai berikut

$$w(j) = \frac{1}{(1 - \text{nilai support}(j))}$$

$$w(1) = \frac{1}{(1 - 0.15)} = 1.18$$

Jika diberikan nilai *group support* minimum 0.02 dan nilai *group confidence* minimum 0.2, Maka bobot untuk tiap atribut seperti pada tabel 3.4

Tabel 3.4 Tabel Bobot Atribut

	Weight
<i>alcohol</i>	1.18
<i>sulphates</i>	1.11
<i>pH</i>	1.18
<i>fixed acidity</i>	1.11
<i>volatile acidity</i>	1.11

3.5.4 Pencarian Centroid Awal Pada Data Latih

Proses pencarian centroid awal dilakukan untuk menentukan centroid yang dipakai sebagai acuan dalam proses LVQ. Data centroid awal ditampilkan pada tabel 3.5

Tabel 3.5 Tabel Centroid Awal

no	alcohol	sulphates	pH	fixed acidity	volatile acidity	class
1	0.13	0.42	0.28	0.22	0.5	3
2	0.39	0.29	0.85	0.09	0.87	4
3	0.55	0.87	0.22	0.15	0.24	5

3.5.5 Proses Learning Vector Quantization

- **Pencarian jarak antara data centroid dengan data latih**

Pada proses ini terjadi perubahan data centroid secara bertahap, dimana dilakukan perhitungan jarak antara data centroid dengan data latih terlebih dahulu dan dicari jarak terdekat antara keduanya. Dari hasil yang diperoleh, akan dibandingkan kelas dari data centroid dengan kelas data latih terdekat. Jika kelas sama, centroid akan digeser mendekati data data latih terdekat, dan jika berbeda kelas, data centroid akan menjauh dari data latih terdekat.

Perhitungan jarak data uji dengan data centroid pertama sebagai berikut,

$$distance(X_1, C_1) = \sum_{i=1}^n w[j] * |X_{1i} - C_{1i}|$$

$$distance(X_1, C_1) = 1.18|0.13 - 0.13| + 1.11|0.68 - 0.42| + 1.18|0.41 - 0.28| +$$

$$1.11|0.54 - 0.22| + 1.11|0.15 - 0.5|$$

$$distance(X_1, C_1) = 0.59$$

$$distance(X_1, C_2) = 1.13$$

$$distance(X_1, C_3) = 0.68$$

Jarak terdekat antara data latih terhadap data centroid berada pada jarak terhadap data centroid ke-1, yaitu 0.59.

- Update centroid berdasarkan jarak terdekat**

Dari perhitungan jarak terdekat yang diperoleh, dibandingkan kelas data uji dengan data centroid terdekat. Jika jarak kelas data uji sama dengan kelas data centroid. Perubahan nilai data centroid dilakukan pada tiap atribut dengan persamaan

$$c_{wj} = c_{wj} - lr(x_{ij} - c_{wj})$$

$$c_{w1} = 0.13 - 0.05(0.13 - 0.13) = 0.13$$

$$c_{w2} = 0.42 - 0.05(0.68 - 0.42) = 0.41$$

$$c_{w3} = 0.28 - 0.05(0.41 - 0.28) = 0.27$$

$$c_{w4} = 0.22 - 0.05(0.54 - 0.22) = 0.2$$

$$c_{w5} = 0.5 - 0.05(0.15 - 0.5) = 0.52$$

Pergeseran data centroid terjadi terus menerus sampai batas epoh yang ditentukan atau jika telah mencapai batas *error* yang ditentukan. *Learning rate* akan turun secara berkala dengan persamaan

$$lr = \frac{lr}{1+lr}$$

$$lr = 0.05/(1 + 0.05) = 0.048$$

Iterasi dilakukan sampai 500 kali sehingga diperoleh data centroid yang telah berubah pada tabel 3.6 dan *learning rate* mencapai 0.002.

Tabel 3.6 Tabel Centroid Akhir

no	alcohol	sulphates	ph	fixed acidity	volatile acidity	class
0	0.03	0.32	0.25	0.42	0.75	3
1	0.73	0.52	0.6	0.17	0.94	4
2	0.58	0.64	0.21	0.04	0.02	5

3.5.6 Proses Klasifikasi

Pada proses ini dilakukan pencarian jarak terdekat antara data uji dengan data centroid. Kelas pada data uji sesuai dengan kelas yang ada pada data centroid terdekat.

$$distance(X_1, C_1) = \sum_{i=1}^n w[j] * |X_{1i} - C_{1i}|$$

$$distance = 1.18|0.08 - 0.03| + 1.11|0.39 - 0.32| + 1.18|0.59 - 0.25| +$$

$$1.11|0.15 - 0.42| + 1.11|0.21 - 0.75|$$

$$distance = 0.74$$

$$distance(X_1, C_2) = 1.05$$

$$distance(X_1, C_3) = 0.77$$

Dari pencarian jarak terdekat antara data uji dengan data centroid, diperoleh jarak terdekat yaitu 0.74, terdapat pada centroid pertama yang mewakili kelas ke-3, maka data uji pada perhitungan manual ini diklasifikasikan ke dalam kelas 3. Sedangkan pada hasil yang diperoleh sistem, data uji juga diklasifikasikan pada kelas 3. Sehingga sistem sudah sesuai dengan perhitungan manual dan dapat digunakan dalam uji coba selanjutnya dengan data yang lebih besar.

3.6 Perancangan Uji Coba

Setelah sistem selesai dibuat, langkah selanjutnya adalah melakukan pengujian terhadap sistem tersebut. Pengujian dilakukan untuk mengetahui tingkat akurasi dari hasil klasifikasi kualitas *wine* menggunakan *Learning Vector Quantization* berbasis asosiasi. Pengujian dilakukan terhadap *dataset red wine quality* dan *white wine quality*.

Terdapat 3 macam pengujian yang dilakukan dalam penelitian ini, yaitu:

1. Pengujian untuk mengetahui pengaruh nilai minimum *support* dan minimum *confidence* terhadap hasil akurasi.
2. Pengujian untuk mengetahui pengaruh *learning rate* terhadap hasil akurasi.
3. Pengujian untuk mengetahui pengaruh jumlah data latih terhadap hasil akurasi
4. Pengujian untuk mengetahui pengaruh jumlah epoh terhadap hasil akurasi.

3.6.1 Pengujian untuk mengetahui pengaruh nilai minimum support dan minimum confidence terhadap hasil akurasi.

Pengujian untuk mengetahui pengaruh nilai minimum *group support* dan minimum *group confidence* terhadap hasil akurasi dilakukan dengan menggunakan nilai minimum *group support* yang berbeda-beda, dimulai dengan 0 sampai dengan 0.072 dengan kenaikan 0.008 di setiap pengujinya. Pengujian dilakukan sebanyak 10 kali di setiap nilai minimum *group support* dan diambil rata-rata akurasinya. Pengujian ini dilakukan dengan nilai minimum *group confidence* 0.5, *learning rate* 0.05, jumlah data latih sebanyak 75% dari data keseluruhan, maximum epoch 1000, serta dengan epsilon 10^{-3} .

Tabel 3.7 menunjukkan rancangan tabel yang akan digunakan dalam pengujian pengaruh nilai *minimum group support* terhadap hasil akurasi.

Tabel 3.7 Tabel rancangan pengujian pengaruh *nilai minimum support*

Min Group Support	Uji Random 1	Uji Random 2	...	Uji Random 9	Uji Random 10	Rata-rata
0						
0.008						
...						
0.064						
0.072						

3.6.2 Pengujian untuk mengetahui pengaruh learning rate terhadap hasil akurasi

Pengujian untuk mengetahui pengaruh learning rate terhadap hasil akurasi dilakukan dengan menggunakan learning rate yang berbeda-beda, dimulai dengan 0.1001 sampai dengan 0.0001 dengan kenaikan 0.01 di setiap pengujinya. Pengujian dilakukan sebanyak 10 kali di setiap *learning rate* dan diambil rata-rata akurasinya. Pengujian ini dilakukan dengan nilai dari minimum *group support* terbaik pada pengujian pertama, nilai minimum *group confidence* 0.5, jumlah data latih sebanyak 75% dari data keseluruhan, maximum epoch 1000, serta dengan epsilon 10^{-3} .

Tabel 3.8 menunjukkan rancangan tabel yang akan digunakan dalam pengujian pengaruh *learning rate* terhadap hasil akurasi.

Tabel 3.8 Tabel rancangan pengujian pengaruh learning rate

Learning Rate	Uji Random 1	Uji Random 2	...	Uji Random 9	Uji Random 10	Rata-rata
0.1001						
0.0901						
...						
0.0101						
0.0001						

3.6.3 Pengujian untuk mengetahui pengaruh jumlah data terhadap hasil akurasi

Pengujian untuk mengetahui pengaruh jumlah data latih terhadap hasil akurasi dilakukan dengan menggunakan jumlah data latih yang berbeda-beda, dimulai dengan 10% sampai dengan 90% dengan kenaikan 10% di setiap pengujinya. Pengujian dilakukan sebanyak 10 kali di setiap *learning rate* dan diambil rata-rata akurasinya. Pengujian ini dilakukan dengan nilai dari minimum *group support* terbaik pada pengujian pertama, nilai minimum *group confidence* 0.5, *learning rate* terbaik dari pengujian kedua, *maximum epoch* 1000, serta dengan epsilon 10^{-3} .

Tabel 3.9 menunjukkan rancangan tabel yang akan digunakan dalam pengujian pengaruh jumlah data latih terhadap hasil akurasi.

Tabel 3.9 Tabel rancangan pengujian pengaruh jumlah data latih

Jumlah Data Latih	Uji Random 1	Uji Random 2	...	Uji Random 9	Uji Random 10	Rata-rata
10%						
20%						
...						
80%						
90%						

3.6.4 Pengujian untuk mengetahui pengaruh maximum epoch terhadap hasil akurasi

Pengujian untuk mengetahui pengaruh maximum epoch terhadap hasil akurasi dilakukan dengan menggunakan maximum epoch yang berbeda-beda, dimulai dengan 100 sampai dengan 5000. Pengujian dilakukan sebanyak 10 kali di setiap jumlah data latih dan diambil rata-rata akurasinya. Pengujian ini dilakukan dengan nilai dari *minimum group support* terbaik pada pengujian pertama, nilai *minimum group confidence* 0.5, *learning rate* terbaik dari pengujian kedua, jumlah data latih 75%, serta dengan epsilon 10^{-3} .

Tabel 3.10 menunjukkan rancangan tabel yang akan digunakan dalam pengujian pengaruh *maximum epoch* terhadap hasil akurasi.

Tabel 3.10 Tabel rancangan pengujian pengaruh *maximum epoch*

Max Epoh	Uji Random 1	Uji Random 2	...	Uji Random 9	Uji Random 10	Rata-rata
100						
400						
...						
4000						
5000						

BAB IV

IMPLEMENTASI

4.1 Lingkungan Implementasi

Lingkungan implementasi yang akan dijelaskan dalam sub bab ini adalah lingkungan implementasi perangkat keras dan perangkat lunak.

4.1.1 Lingkungan Perangkat Keras

Perangkat keras yang digunakan dalam pengembangan perangkat lunak ini adalah sebagai berikut :

- Intel® Core™ i5CPU 650 @ 3,20GHz
- Memori 4 GB
- Harddisk 500 GB
- Monitor 21”
- Keyboard
- Mouse

4.1.2 Lingkungan Perangkat Lunak

Perangkat lunak yang digunakan dalam pengembangan perangkat lunak ini adalah sebagai berikut :

- Sistem Operasi Windows 8 Professional 64 bit
- Adobe Dreamweaver CS4
- Codeigniter 2.0.0
- XAMPP 1.7.2
- Apache 2.4.3
- MySQL 5.5.27
- PHP 5.4.7
- PhpMyAdmin 3.5.2.2

4.2 Implementasi Program

Berdasarkan analisa dan perancangan proses yang terdapat pada bab 3, maka pada subbab ini akan dijelaskan implementasi proses-proses tersebut.

4.2.1 Implementasi Transformasi Data

Proses implementasi konversi data yang dilakukan ialah mengambil seluruh data dari *database* dan dikonversikan ke dalam bentuk array dua dimensi `$arrayData`, dimana row pada array tersebut merupakan *instances* dan *column* akan menjadi *feature* yang ada pada tiap *instance*. Implementasi langkah ini seperti ditunjukkan pada Source Code 4.1.

```
// proses konversi data
$qData = $this->db->query("SELECT * FROM reddata");
$i=0;
foreach ($qData->result() as $row)
{
    $arrayRaw[$i][0] = $i;
    $arrayRaw[$i][1] = $row->fix_acid;
    $arrayRaw[$i][2] = $row->vol_acid;
    $arrayRaw[$i][3] = $row->cit_acid;
    $arrayRaw[$i][4] = $row->res_sugar;
    $arrayRaw[$i][5] = $row->chlorides;
    $arrayRaw[$i][6] = $row->fsd;
    $arrayRaw[$i][7] = $row->tsd;
    $arrayRaw[$i][8] = $row->density;
    $arrayRaw[$i][9] = $row->ph;
    $arrayRaw[$i][10] = $row->sulphates;
    $arrayRaw[$i][11] = $row->alcohol;
    $arrayRaw[$i][$feature-1] = ($row->class-3); // start with 0;
    $i++;
}
```

Gambar 4.1 Source Code Konversi Data

Proses implementasi transformasi data pada program ini menggunakan normalisasi, normalisasi bertujuan untuk menghindari nilai yang dominan pada atribut yang mempunyai *range* besar sehingga akan mempengaruhi pada proses perhitungan jarak. Normalisasi yang digunakan pada proses ini adalah normalisasi min-max dan normalisasi dilakukan terhadap data latih maupun data uji. Implementasi normalisasi pada data latih seperti ditunjukkan pada Source Code 4.3.

```
//normalisasi
$arrayTmp = array();
for($i=1;$i<$feature-1;$i++)
{
```

```
$maxData = 0;
$minData = 0;
for($j=0;$j<count($arrayRaw);$j++)
{
    $arrayTmp[$j] = $arrayRaw[$j][$i];
}

$maxData = max($arrayTmp);
$minData = min($arrayTmp);
for($k=0;$k<count($arrayRaw);$k++)
{
    $arrayData[$k][$i] = round( ($arrayTmp[$k] - $minData) /
($maxData - $minData) ,2);
}
}
```

Gambar 4.2 Source Code Normalisasi Data

Dalam implementasi normalisasi ini dilakukan pada tiap atribut yang ada. Dan pada setiap atribut, data akan dirubah menjadi array satu dimensi terlebih dahulu untuk mempermudah perhitungan ($\$arrayTmp$). Setelah itu pada $\$arrayTmp$ akan dicari nilai maksimum dan minimumnya ($\$maxData = \max(\$arrayTmp)$ dan $\$minData = \min(\$arrayTmp)$). Setelah ditemukan nilai maksimum dan minimumnya, dilakukan normalisasi pada tiap data dengan menggunakan persamaan yang ada.

4.2.2 Pecah Data Transformasi

Selanjutnya data akan dipecah menjadi dua, yang pertama untuk data latih dan yang kedua untuk data uji. Pemecahan data dilakukan pada setiap kelas. Sehingga perbandingan jumlah data uji dan data latih pada setiap kelas sama. Dalam proses pecah data, data yang berindeks kurang dari jumlah data latih di setiap kelas akan dijadikan data latih, dan sisanya dijadikan data uji.

Pengambilan data centroid awal dilakukan pada setiap iterasi perkelas, data centroid awal diambil setelah pecah data antara data latih dengan data uji pada setiap kelas. Sebelumnya pengambilan data centroid, data latih perkelas akan diacak sehingga akan menghasilkan data centroid yang beragam. Implementasi langkah ini seperti ditunjukkan pada *Source Code 4.2*.

```
for($i=0;$i<$jumlahKelas;$i++)
{
    $idx=0;
    unset($arrayTmp1);
```

```
for($j=0;$j<count($arrayData);$j++)
{
    if($arrayData[$j][$feature-1]==$i)
    {
        for($v=0;$v<$feature;$v++)
        {
            $arrayTmp1[$idx][$v]=$arrayData[$j][$v];
        }
        $idx++;
    }
}
$arrayTmp2=array();
unset($arrayTmp2);
for($j=0;$j<count($arrayTmp1);$j++)
{
    if($j<round(($dataTraining/100)*count($arrayTmp1),0))
    {
        for($v=0;$v<$feature;$v++)
        {
            $arrayLatih[$indexLatih][$v]=$arrayTmp1[$j][$v];
            $arrayTmp2[$indexLatih][$v]=$arrayTmp1[$j][$v];
        }
        $indexLatih++;
    }
    else
    {
        for($v=0;$v<$feature;$v++)
        {
            $arrayUji[$indexUji][$v]=$arrayTmp1[$j][$v];
        }
        $indexUji++;
    }
}
// shuffle array
shuffle($arrayTmp2);
$arrayTmp2 = array_merge($arrayTmp2);
for($v=0;$v<$feature;$v++)
{
    $arrayCentroid[$i][$v]=$arrayTmp2[0][$v];
}
// shuffle array
shuffle($arrayTmp2);
$arrayTmp2 = array_merge($arrayTmp2);

for($v=0;$v<$feature;$v++)
{
    $arrayCentroid1[$i][$v]=$arrayTmp2[0][$v];
}
// shuffle array
shuffle($arrayTmp2);
$arrayTmp2 = array_merge($arrayTmp2);

for($v=0;$v<$feature;$v++)
{
    $arrayCentroid2[$i][$v]=$arrayTmp2[0][$v];
}
}
```

Gambar 4.3 Source Code Pecah Data

4.2.3 Proses Pencarian Bobot

Dalam implementasi pencarian bobot ini, iterasi dilakukan pada tiap atribut yang ada sebanyak jumlah atribut yang ada. Dan pada setiap atribut, data akan dirubah menjadi array satu dimensi terlebih dahulu untuk mempermudah perhitungan (\$arrayA). Dalam pencarian nilai *group support* dilakukan pencarian nilai yang sama pada tiap \$arrayA dan dimasukkan ke dalam \$arrayB dan \$arrayC. Di mana \$arrayB merupakan distribusi nilai yang ada pada \$arrayA dan \$arrayB merupakan jumlah data yang terdapat pada \$arrayB. Implementasi pencarian nilai *group support* seperti ditunjukkan pada Source Code 4.4.

```
unset($arrayA);
unset($arrayB);
unset($arrayC);
unset($arrayD);

// ubah data Latih per atribut menjadi array
for($j=0;$j<count($arrayLatih);$j++)
{
    $arrayA[$j] = $arrayLatih[$j][$v];
}

// pencarian group support
for($i=0;$i<count($arrayA);$i++)
{
    if($i==0)
    {
        $arrayB[0] = $arrayA[$i];
        $arrayC[0] = 1;
    }
    else
    {
        $ketemu = 0; // false
        for($j=0;$j<count($arrayB);$j++)
        {
            if ($arrayA[$i] == $arrayB[$j])
            {
                $arrayC[$j] = $arrayC[$j] + 1;
                $ketemu = 1;
                break;
            }
        }
        if($ketemu==0)
        {
            $arrayB[count($arrayB)] = $arrayA[$i];
            $arrayC[count($arrayC)] = 1;
        }
    }
}
```

Gambar 4.4 Source Code Pencarian Nilai Group Support

Dalam implementasi pencarian nilai *group confidence*, dilakukan iterasi sebanyak jumlah \$arrayB. Dalam iterasi ini, dicari jumlah yang terbesar dan

memiliki kelas yang sama tiap \$arrayB. Dan nilai terbesar yang ada pada tiap \$arrayB akan dimasukkan ke dalam \$arrayD. Implementasi pencarian nilai group confidence seperti ditunjukkan pada Source Code 4.5.

```
// pencarian group confidence
for($i=0;$i<count($arrayB);$i++)
{
    $arrayPerKelas = array(0,0,0,0,0,0); // SESUAI JUMLAH KELAS
    for($j=0;$j<count($arrayTraining);$j++)
    {
        if($arrayB[$i]==$arrayA[$j])
        {
            for($k=0;$k<$jumlahKelas;$k++)
            {
                if($arrayTraining[$j][$feature-1]==$k+1)
                {
                    $arrayPerKelas[$k] =
$arrayPerKelas[$k]+1;
                }
            }
        }
    }
    $arrayD[$i] = max($arrayPerKelas)/$arrayC[$i];
}
```

Gambar 4.5 Source Code Pencarian Nilai Group Confidence

Dalam pencarian nilai bobot atribut yang akan digunakan dalam proses selanjutnya, dilakukan terlebih dahulu pengecekan terdapat input yang dimasukkan oleh *user* terhadap nilai *minimum group support* dan *minimum group confidence*nya. Jika nilai *group support* (\$arrayWfeature[\$rr][1]) lebih kecil dari nilai *minimum group support* dan jika nilai *group confidence* (\$arrayWfeature[\$rr][2]) lebih kecil dari nilai *minimum group confidence* maka nilai bobot (\$arrayWfeature[\$rr][3]) pada atribut tersebut bernilai nol. Dan jika tidak, nilai bobot atribut dihitung dengan persamaan yang ada. Implementasi perhitungan nilai bobot tiap atribut seperti ditunjukkan pada Source Code 4.6.

```
$arrayWfeature[$v][0] = round(max($arrayC)/count($arrayA),3);
$arrayWfeature[$v][1] = round(max($arrayD),3); $arrayWfeature[$v][2] =
1/(1-$arrayWfeature[$v][0]);
if($arrayWfeature[$v][0]<$minSup OR $arrayWfeature[$v][1] < $minConf )
{$arrayWfeature[$v][2] = 0;}
else
{$arrayWfeature[$v][2] = round($arrayWfeature[$v][2],3) ; }
```

Gambar 4.6 Source Code Perhitungan Nilai Bobot

4.2.4 Proses Learning Vector Quantization

Dalam implementasi *learning vector quantization*, dilakukan beberapa iterasi di dalamnya, yang pertama adalah iterasi dengan batas maksimum epoh (\$maxEpoh). Iterasi kedua sebanyak jumlah data latih (\$arrayLatih). Pada setiap data latih, dicari jarak terdekat terhadap data centroid (\$arrayCentroid). Lalu dilakukan pengecekan antara kelas data latih dengan kelas data centroid terdekat. Update data centroid dilakukan berdasarkan sama atau tidaknya kelas antara daa latih dengan data centroid terdekat. Dan pada setiap pergeseran data centroid terdekat, juga dilakukan pencarian nilai epsilonnya. Jika nilai epsilon (\$epsilon) lebih kecil dari batas *error rate* yang dimasukkan oleh *user*. Jika nilai epsilon lebih kecil dari batas *error rate*, maka iterasi terhadap epoh akan berhenti. Perhitungan ini dilakukan sebanyak jumlah data latih yang ada. Penurunan *learning rate* (\$lr) dilakukan pada setiap pergantian nilai epoh yang ada. Implementasi proses *learning vector quantization* seperti ditunjukkan pada *Source Code 4.7*.

```
// proses LVQ
for($epoh=0;$epoh<$maxEpoh;$epoh++)
{
    for($i=0;$i<count($arrayTraining);$i++)
    {
        winRow = 0;
        $minDistance = 10000;$distance = 0;
        for($c=0;$c<count($arrayCentroid);$c++)
        {
            $distance = 0;
            for($v=1;$v<$feature-1;$v++)
            {
                $distance = $distance +
$arraywfeature[$v][3]*(abs($arrayTraining[$i][$v]-
$arrayCentroid[$c][$v]));
            }
            if($distance <= $minDistance)
            {
                $minDistance = $distance;
                $winRow = $c;
            }
        }
        // update vector
        $epsilon = 0;
        if($arrayTraining[$i][$feature-1]==$winRow)
        {
            for($v=1;$v<$feature-1;$v++)
            {
                $arrayCentroid[$winRow][$v] =
$arrayCentroid[$winRow][$v] + ($lr*($arrayTraining[$i][$v]-
$arrayCentroid[$winRow][$v]));
                if($arrayCentroid[$winRow][$v]>1)
                { $arrayCentroid[$winRow][$v]=1; }
            }
        }
    }
}
```

```
        else if($arrayCentroid[$winRow][$v]<0)
        { $arrayCentroid[$winRow][$v]=0; }
    $epsilon = $epsilon + abs($lr*($arrayTraining[$i][$v]-
$arrayCentroid[$winRow][$v]));
}
else
{
    for($v=1;$v<$feature-1;$v++)
    {
        $arrayCentroid[$winRow][$v] =
$arrayCentroid[$winRow][$v] - ($lr*($arrayTraining[$i][$v]-
$arrayCentroid[$winRow][$v]));
        if($arrayCentroid[$winRow][$v]>1)
        { $arrayCentroid[$winRow][$v]=1; }
        else if($arrayCentroid[$winRow][$v]<0)
        { $arrayCentroid[$winRow][$v]=0; }
    $epsilon = $epsilon + abs($lr*($arrayTraining[$i][$v]-
$arrayCentroid[$winRow][$v]));
    }
}
if($epsilon<$epsilon_max)
{ $maxEpoch=0; }
$lr = $lr/(1+$lr);
}
```

Gambar 4.7 Source Code Learning Vector Quantization

4.2.5 Klasifikasi

Dalam implementasi klasifikasi ini, dilakukan pencarian jarak terdekat menggunakan antara setiap data uji (`$arrayUji`) terhadap data centroid (`$arrayCentroid`) menggunakan Euclidean Distance. Jika kelas yang ada pada data uji sama dengan kelas data centroid terdekat (`$winRow`) maka nilai true bertambah satu (`$true`). Implementasi proses klasifikasi seperti ditunjukkan pada *Source Code 4.8*.

```
// perhitungan akurasi
$true=0;
for($i=0;$i<count($arrayUji);$i++)
{
    $winRow = 0;$minDistance = 10000;$distance = 0;
    for($c=0;$c<count($arrayCentroid);$c++)
    {
        $distance = 0;
        for($v=1;$v<$feature-1;$v++)
        {
            $distance = $distance +
$arraywfeature[$v][3]*(abs($arrayUji[$i][$v]-$arrayCentroid[$c][$v]));
        }
        $distance = pow($distance,0.5);
        if($distance <= $minDistance)
        {
            $minDistance = $distance;$winRow = $c;
        }
    }
}
```

```
        }
    }
    if($arrayUji[$i][$feature-1]==$winClass)
    { $true = $true+1; }
```

Gambar 4.8 Source Code Klasifikasi

4.3 Implementasi Antarmuka

4.3.1 Antarmuka Lihat Data

Antarmuka lihat data merupakan detil dari *dataset* asli sebelum diolah oleh sistem. Antarmuka lihat data ditunjukkan pada gambar 4.9.

The screenshot shows the LVQBA Learning Vector Quantization Berbasis Asosiasi application. At the top, there's a red header bar with the title 'LVQBA Learning Vector Quantization Berbasis Asosiasi' and tabs for 'Red Wine Quality' and 'White Wine Quality'. Below the header, on the left, is a sidebar titled 'Red Wine Quality' containing a list of items: 'Dataset Red Wine', 'Form Red Wine LVQBA', 'Skenario Pengujian 01', 'Skenario Pengujian 02', 'Skenario Pengujian 03', 'Skenario Pengujian 04', and 'Analisa'. On the right, there's a main table titled 'Red Wine Datasets' with 15 rows of data. The columns are labeled: no, fixed acidity, volatile acidity, citric acid, residual sugar, chlorides, free sulfur dioxide, total sulfur dioxide, density, pH, and sul. The data rows show various values for these parameters.

no	fixed acidity	volatile acidity	citric acid	residual sugar	chlorides	free sulfur dioxide	total sulfur dioxide	density	pH	sul
0	7.4	0.7	0	1.9	0.076	11	34	0.9978	3.51	
1	7.8	0.88	0	2.6	0.098	25	67	0.9968	3.2	
2	7.8	0.76	0.04	2.3	0.092	15	54	0.997	3.26	
3	11.2	0.28	0.56	1.9	0.075	17	60	0.998	3.16	
4	7.4	0.7	0	1.9	0.076	11	34	0.9978	3.51	
5	7.4	0.66	0	1.8	0.075	13	40	0.9978	3.51	
6	7.9	0.6	0.06	1.6	0.069	15	59	0.9964	3.3	
7	7.3	0.65	0	1.2	0.065	15	21	0.9946	3.39	
8	7.8	0.58	0.02	2	0.073	9	18	0.9968	3.36	
9	7.5	0.5	0.36	6.1	0.071	17	102	0.9978	3.35	
10	6.7	0.58	0.08	1.8	0.097	15	65	0.9959	3.28	
11	7.5	0.5	0.36	6.1	0.071	17	102	0.9978	3.35	
12	5.6	0.615	0	1.6	0.089	16	59	0.9943	3.58	
13	7.8	0.61	0.29	1.6	0.114	9	29	0.9974	3.26	
14	8.9	0.62	0.18	3.8	0.176	52	145	0.9986	3.16	
15	8.9	0.62	0.19	3.9	0.17	51	148	0.9986	3.17	

Gambar 4.9 Antarmuka Lihat Data

4.3.2 Antarmuka Input Parameter Pengujian

Antarmuka *input parameter* merupakan detil inputan yang akan digunakan sebagai parameter dalam proses *learning vector quantization* berikutnya. Input yang dimasukkan berupa jumlah data latih dalam satuan persen, nilai *minimum support*, nilai *minimum confidence* dan *learning rate*. Jumlah data latih yang disediakan dalam inputan ini yaitu 10%-90%. Nilai *minimum support* dan *minimum confidence* 0-0.5, serta *learning rate* 0.002 hingga 0.02.

Antarmuka input parameter pengujian ditunjukkan pada gambar 4.10.

The screenshot shows the LVQBA application interface. At the top, there is a red header bar with the text "LVQBA Learning Vector Quantization Berbasis Asosiasi" and two tabs: "Red Wine Quality" and "White Wine Quality". Below the header, on the left, is a vertical menu with options: "Red Wine Quality", "Dataset Red Wine", "Form Red Wine LVQBA" (which is highlighted in red), "Skenario Pengujian 01", "Skenario Pengujian 02", "Skenario Pengujian 03", "Skenario Pengujian 04", and "Analisa". The main area contains a form titled "Form LVQBA - Red Wine Quality" with the following fields: "Min. Support : 0.025", "Min. Conf. : 0.5", "learning rate : 0.031", "Data Latih (%) : 75", "max epoch : 1000", and "min epsilon : 0.000001". There is also a "Submit" button.

Gambar 4.10 Antarmuka Form Input

4.3.3 Antarmuka Hasil Pengujian

Antarmuka hasil pengujian merupakan antarmuka untuk memperlihatkan hasil pengujian yang dilakukan oleh sistem dengan parameter tertentu. Antarmuka hasil pengujian ditunjukkan pada gambar 4.11.

The screenshot shows the LVQBA application interface. At the top, there is a red header bar with the text "LVQBA Learning Vector Quantization Berbasis Asosiasi" and two tabs: "Red Wine Quality" and "White Wine Quality". Below the header, a message states: "Pengujian Pengaruh Nilai Minimum Support terhadap dataset red wine, dengan MinConf 0.5, learning rate 0.05 , jumlah data latih %, maximum epoch 500 dan epsilon 0.001". The main area contains a table titled "Hasil Akurasi" with the following data:

Pengujian	minimum Support	minimum Confidence	learning rate	data latih (%)	data latih	data uji	maximum epoch	Centroid 1	Centroid 2	Centroid 3	Akurasi Terbaik
1	0	0.5	0.05	75%	1201	398	500	45.23	43.47	39.95	45.23
1	0.005	0.5	0.05	75%	1201	398	500	41.46	41.71	46.23	46.23
1	0.01	0.5	0.05	75%	1201	398	500	43.97	44.47	40.45	44.47
1	0.015	0.5	0.05	75%	1201	398	500	45.23	41.96	42.96	45.23
1	0.02	0.5	0.05	75%	1201	398	500	44.97	43.72	43.72	44.97
1	0.025	0.5	0.05	75%	1201	398	500	44.22	43.97	42.46	44.22
1	0.03	0.5	0.05	75%	1201	398	500	43.97	42.71	41.21	43.97
1	0.035	0.5	0.05	75%	1201	398	500	45.48	43.22	44.22	45.48
1	0.04	0.5	0.05	75%	1201	398	500	43.97	44.97	43.22	44.97
1	0.045	0.5	0.05	75%	1201	398	500	42.21	42.71	43.72	43.72
1	0.05	0.5	0.05	75%	1201	398	500	40.95	42.21	43.22	43.22
1	0.055	0.5	0.05	75%	1201	398	500	39.2	40.2	38.69	40.2

Gambar 4.11 Antarmuka Hasil Pengujian

4.3.4 Antarmuka Hasil Perhitungan Normal

Antarmuka hasil merupakan antarmuka untuk memperlihatkan hasil yang dilakukan oleh sistem. Pada kolom kiri ditampilkan inputan yang dimasukkan oleh user, proses *learning vector quantization* dengan menampilkan perubahan terhadap *learning rate* dan epsilon, serta hasil akurasi menggunakan berbagai beberapa macam perhitungan jarak (Manhattan, Euclidean, dan Minkowski Distance). Pada kolom kanan baris pertama, ditampilkan data latih, data uji, bobot pada atribut, centroid awal, dan centroid akhir. Pada baris kedua ditampilkan perbandingan perhitungan jarak (Manhattan, Euclidean, dan Minkowski Distance) yang dilakukan oleh data uji terhadap centroid akhir.

Antarmuka hasil proses ditunjukkan pada gambar 4.12.

The screenshot shows a Java Swing application window titled "LVQBA Learning Vector Quantization Berbasis Asosiasi".

Form Input:

```
Data: 1599 dataLatih: 1359 dataUji: 240
minSupp: 0.025 minConf: 0.5
MaxEpoch: 5000 Epsilon: 0.0000001 LRate:
0.031
```

Data Latih:

	Data Latih	Data Uji	Weight Feature	Centroid Awal	Centroid Akhir
1	0.052	1	1.066		
2	0.047	1	1.049		
3	0.081	1	1.088		
4	0.177	1	1.215		
5	0.196	1	1.244		
6	0.087	1	1.095		
7	0.058	1	1.062		
8	0.048	1	1.05		
9	0.057	1	1.06		

Centroid 1 | Centroid 2 | Centroid 3

Perbandingan Hasil Akurasi dan Klasifikasi tiap Data Uji

Hasil Akurasi : 48.33

Klasifikasi per data Uji

Manhattan	Euclidean	Minkowski R=3	Minkowski R=4	Minkowski R=5
45	48.33	46.25	46.25	47.92

Acc : 49.17 %

Gambar 4.12 Antarmuka Hasil Perhitungan Normal

BAB V

ANALISA DAN PEMBAHASAN

5.1. Pengujian

Pada subbab ini akan dilakukan pembahasan mengenai pengujian yang telah dilakukan pada sistem dan hasil evaluasi dari sistem tersebut. Pada pengujian klasifikasi digunakan dataset *red wine quality* dan *white wine quality* yang berasal dari UCI *Machine Learning*. Terdapat 1599 data *red wine quality* dan 4898 data *white wine quality*. Dalam pengujian ini terdapat jumlah data latih, nilai *minimum support*, nilai *minimum confidence* yang beragam. Pengujian terhadap klasifikasi *wine quality* menggunakan algoritma *learning vector quantization* berbasis asosiasi dibagi menjadi tiga, yaitu pengujian untuk mengetahui pengaruh *minimum support*, *minimum confidence* dan *learning rate*, serta pengaruh jumlah data latih terhadap hasil akurasi pada klasifikasi kualitas minuman anggur.

5.2 Hasil Uji

Seperti yang dibahas pada bab 3, terdapat 4 macam pengujian yang dilakukan untuk mengetahui pengaruhnya terhadap hasil akurasi. Pengujian yang pertama dilakukan untuk mengetahui pengaruh nilai *minimum group support*. Pengujian kedua untuk mengetahui pengaruh *learning rate*. Pengujian ketiga untuk mengetahui pengaruh jumlah data latih, dan yang ketiga untuk mengetahui pengaruh *maximum epoch*.

5.2.1 Pengujian untuk mengetahui pengaruh nilai *minimum support* dan *minimum confidence* terhadap hasil akurasi

Pada pengujian untuk mengetahui pengaruh *minimum support* dan *minimum confidence* terhadap hasil akurasi, dilakukan pengujian terhadap *dataset wine quality* dengan *learning rate*, jumlah data latih, dan epoh yang konstan. Untuk nilai *minimum support* antara 0 sampai 0.072. Berdasarkan pada penelitian sebelumnya, pengujian untuk pengaruh *minimum confidence* tidak dilakukan karena tidak berpengaruh terhadap hasil akurasi pada *dataset wine quality*.

Dalam pengujian pengaruh nilai *minimum support* terhadap *dataset red wine*. Dengan *learning rate* 0.05, jumlah data latih 75% dari jumlah data *red wine*, maksimum epoch 1000 dan batas *error* 0.001, didapatkan hasil pengujian terhadap *dataset red wine* seperti ditampilkan pada tabel 5.1

Tabel 5.1 Tabel pengaruh nilai minimum support terhadap hasil akurasi dataset *red wine*

Min Supp	Uji 1	Uji 2	Uji 3	Uji 4	Uji 5	Uji 6	Uji 7	Uji 8	Uji 9	Uji10	Rata-rata
0	52.26	56.53	47.24	51.01	46.73	53.27	52.01	50.25	47.74	48.99	50.603
0.008	52.26	56.53	47.24	51.01	46.73	53.27	52.01	50.25	47.74	48.99	50.603
0.016	52.26	56.53	47.24	51.01	46.73	53.27	52.01	50.25	47.74	48.99	50.603
0.024	52.26	56.53	47.24	51.01	46.73	53.27	52.01	50.25	47.74	48.99	50.603
0.032	52.26	56.53	47.24	51.01	46.73	53.27	52.01	50.25	47.74	48.99	50.603
0.04	52.26	56.53	47.24	51.01	46.73	53.27	52.01	50.25	47.74	48.99	50.603
0.048	52.51	43.47	51.26	51.01	50.25	44.22	52.01	49.5	47.74	48.99	49.096
0.056	55.53	42.46	54.02	47.49	55.28	41.96	46.98	43.47	48.99	44.72	48.09
0.064	55.53	42.46	54.02	47.49	55.28	41.96	39.7	43.47	48.99	44.72	47.362
0.072	52.51	44.72	51.26	40.95	50.25	41.96	37.44	43.22	48.49	47.49	45.829

Berdasarkan tabel 5.1, pengujian pengaruh nilai *minimum support* terhadap hasil akurasi *dataset red wine* didapatkan hasil akurasi terbaik pada nilai *minimum support* 0 sampai dengan 0.04 dengan rata-rata akurasi 50.603%.

Sedangkan dalam pengujian pengaruh nilai *minimum support* terhadap *dataset white wine*. Dengan *learning rate* 0.05, jumlah data latih 75% dari jumlah data *white wine*, maksimum epoch 1000 dan batas *error* 0.001, didapatkan hasil pengujian seperti ditampilkan pada tabel 5.2

Tabel 5.2 Tabel pengaruh nilai minimum support terhadap hasil akurasi dataset *white wine*

Min Supp	Uji 1	Uji 2	Uji 3	Uji 4	Uji 5	Uji 6	Uji 7	Uji 8	Uji 9	Uji10	Rata-rata
0	40.52	40.36	38.64	38.32	38.24	39.54	40.6	38.48	38.89	38.73	39.232
0.008	40.52	40.36	38.64	38.32	38.24	39.54	40.6	38.48	38.89	38.73	39.232
0.016	40.52	40.36	38.64	38.32	38.24	39.54	40.6	38.48	38.89	38.73	39.232
0.024	40.52	40.36	38.64	38.32	38.24	39.54	40.6	38.48	38.89	38.73	39.232
0.032	40.52	40.36	38.64	38.32	38.24	39.54	40.6	38.48	38.89	38.73	39.232

0.04	40.52	40.36	38.64	38.32	38.24	39.54	40.6	38.48	38.89	38.73	39.232
0.048	31.29	30.23	32.52	32.27	30.23	26.31	17.81	39.54	39.87	31.78	31.185
0.056	7.27	9.97	32.03	32.11	32.35	10.54	32.68	9.64	6.37	13.97	18.693
0.064	35.87	35.13	18.38	18.3	18.14	25.65	5.23	9.72	9.56	9.64	18.562
0.072	35.87	35.13	18.38	18.3	18.14	25.65	21.81	9.72	9.56	6.62	19.918

Berdasarkan tabel 5.2, pengujian pengaruh nilai *minimum support* terhadap hasil akurasi *dataset red wine* didapatkan hasil akurasi terbaik pada nilai *minimum support* 0 sampai dengan 0.04 dengan rata-rata akurasi 39.232%.

5.2.2 Pengujian untuk mengetahui pengaruh learning rate terhadap hasil akurasi

Pada pengujian untuk mengetahui pengaruh *learning rate* terhadap hasil akurasi, diambil nilai *minimum support* yang memiliki hasil akurasi terbaik dari pengujian sebelumnya. Jumlah data latih yang digunakan pada pengujian ini yaitu 75% dari jumlah data *red wine* serta maximum epoch 1000 dan batas error 0.001. didapatkan hasil pengujian pengaruh *learning rate* pada *dataset red wine* seperti ditampilkan pada tabel 5.3

Tabel 5.3 Tabel pengaruh *learning rate* terhadap hasil akurasi dataset *red wine*

LRate	Uji 1	Uji 2	Uji 3	Uji 4	Uji 5	Uji 6	Uji 7	Uji 8	Uji 9	Uji10	Rata-rata
0.0001	32.91	39.2	37.19	27.89	32.91	29.65	35.43	31.41	27.64	25.88	32.011
0.0101	54.02	47.49	55.03	47.24	45.48	47.24	46.73	57.04	48.24	46.73	49.524
0.0201	61.56	55.03	54.02	50.75	49.75	50.25	53.52	47.49	46.98	45.98	51.533
0.0301	46.48	56.03	47.24	49.5	50.25	48.24	44.72	46.73	47.24	46.73	48.316
0.0401	60.55	49.75	48.74	49.5	49.5	50	43.97	46.48	47.24	47.74	49.347
0.0501	61.56	53.27	52.51	49.25	46.48	46.98	48.99	46.23	48.99	47.24	50.15
0.0601	46.48	50.5	51.26	47.49	46.23	49.5	45.73	46.73	48.99	47.74	48.065
0.0701	54.27	51.26	51.76	47.49	46.48	45.98	49.25	47.74	48.49	49.25	49.197
0.0801	61.06	53.02	49.75	47.99	45.23	47.24	44.22	47.74	47.74	51.26	49.525
0.0901	57.29	55.03	55.03	48.49	50.25	47.49	53.02	46.23	47.24	49.75	50.982
0.1001	61.81	50.25	54.27	48.24	49.25	48.99	45.48	44.22	47.99	48.24	49.874

Berdasarkan tabel 5.3, pengujian pengaruh *learning rate* terhadap hasil akurasi *dataset red wine* didapatkan hasil akurasi terbaik pada *learning rate* 0.0201 dengan rata-rata akurasi 51.53%.

Sedangkan pada pengujian untuk mengetahui pengaruh *learning rate* terhadap hasil akurasi dataset white wine, didapatkan hasil pengujian pengaruh *learning rate* pada *dataset red wine* seperti ditampilkan pada tabel 5.4.

Tabel 5.4 Tabel pengaruh *learning rate* terhadap hasil akurasi dataset *white wine*

LRate	Uji 1	Uji 2	Uji 3	Uji 4	Uji 5	Uji 6	Uji 7	Uji 8	Uji 9	Uji10	Rata-rata
0.0001	29.98	20.1	19.93	22.39	16.75	24.02	31.86	18.22	16.99	21.08	22.132
0.0101	42.73	40.85	42.08	41.09	38.89	42.57	39.87	42.08	32.43	8.01	37.06
0.0201	42.73	39.87	42.16	40.77	40.6	41.83	40.2	41.58	40.36	37.5	40.76
0.0301	42.08	41.91	41.99	40.69	40.77	41.99	36.68	41.18	41.34	38.24	40.687
0.0401	41.83	41.75	41.99	40.52	40.36	42.16	36.44	41.26	41.09	37.83	40.523
0.0501	41.83	41.67	41.99	40.44	40.44	42.16	36.03	40.85	6.45	39.95	37.181
0.0601	41.83	41.58	42.08	40.69	40.44	42.24	31.45	41.18	41.09	38.73	40.131
0.0701	41.99	41.75	42.16	40.28	41.01	42.48	32.43	18.06	40.69	37.75	37.86
0.0801	42.24	42.08	42.32	40.6	40.52	42.32	32.6	38.89	40.77	41.67	40.401
0.0901	42.32	41.99	38.64	40.44	40.44	42.24	33.09	41.26	40.77	37.66	39.885
0.1001	42.08	42.16	38.48	40.28	41.01	5.56	35.87	18.06	40.44	41.67	34.561

Berdasarkan tabel 5.4, pengujian pengaruh learning rate terhadap hasil akurasi dataset white wine didapatkan hasil akurasi terbaik pada learning rate 0.0201 dengan rata-rata akurasi 40.76%.

5.2.3 Pengujian untuk mengetahui pengaruh jumlah data latih terhadap hasil akurasi

Pada pengujian untuk mengetahui pengaruh jumlah data latih terhadap hasil akurasi, diambil nilai minimum *support* dan learning rate yang memiliki hasil akurasi terbaik dari pengujian sebelumnya. Jumlah data latih yang digunakan pada pengujian ini dimulai dari 10% hingga 90% dari jumlah data serta maximum epoch 500 dan batas error 10^{-3} . didapatkan hasil pengujian pengaruh *learning rate* pada *dataset red wine* seperti ditampilkan pada tabel 5.5

Tabel 5.5 Tabel pengaruh jumlah data latih terhadap hasil akurasi dataset *red wine*

Data Latih	Uji1	Uji 2	Uji 3	Uji 4	Uji 5	Uji 6	Uji 7	Uji 8	Uji 9	Uji10	Rata-rata
10%	54.41	55.87	56.91	50.1	52.05	55.73	54.69	48.92	49.76	48.85	52.729
20%	53.76	51.56	56.49	55.95	52.66	54.23	52.74	55.95	52.03	55.4	54.077
30%	53.39	50.27	54.91	53.84	54.82	54.11	45	49.91	46.43	40.8	50.348
40%	51.25	42.08	47.5	49.48	56.35	56.88	56.04	46.35	50.31	51.15	50.739
50%	47.49	47.87	46.24	46.62	51.75	54.26	49.25	44.49	43.48	53.38	48.483
60%	51.8	52.74	46.48	56.96	46.64	39.75	39.44	57.12	46.48	46.79	48.42
70%	43.84	46.14	41.54	48.02	46.35	43.63	44.89	50.1	53.44	45.09	46.304
80%	52.34	52.02	41.74	43.3	40.81	42.06	48.29	42.68	56.7	55.14	47.508
90%	50	56.25	55	42.5	43.75	43.13	51.88	46.25	43.13	45	47.689

Berdasarkan tabel 5.5, pengujian pengaruh jumlah data latih terhadap hasil akurasi dataset red wine didapatkan jumlah data latih terbaik pada pengujian ini ketika data latih berjumlah 20% dari data keseluruhan dengan rata-rata akurasi 54.077%.

Sedangkan pada pengujian untuk mengetahui pengaruh jumlah data latih terhadap hasil akurasi dataset white wine, didapatkan hasil pengujian pengaruh *learning rate* pada dataset white wine seperti ditampilkan pada tabel 5.6.

Tabel 5.6 Tabel pengaruh jumlah data latih terhadap hasil akurasi dataset *white wine*

Data Latih	Uji1	Uji 2	Uji 3	Uji 4	Uji 5	Uji 6	Uji 7	Uji 8	Uji 9	Uji10	Rata-rata
10%	50.85	46.13	43.48	30.66	44.36	47.67	41.64	33.4	45.02	46.56	42.977
20%	44.46	33.51	40.33	39.71	31.9	8.55	14.57	43.11	6.99	20.52	28.365
30%	44.46	39.96	38.62	46.35	32.64	40.61	43.99	46.18	44.05	41.72	41.858
40%	31.81	24.26	43.38	14.36	25.11	43.96	19.36	7.15	16.33	37.7	26.342
50%	38.99	41.85	40.01	38.13	40.78	36.9	38.66	35.51	35.02	27.38	37.323
60%	12.35	37.67	34.66	43.44	22.41	32.06	42.73	41.76	41.19	39.87	34.814
70%	39.31	39.17	28.2	32.9	39.24	41.69	30.25	13.96	31.81	7.22	30.375
80%	38.67	27.96	36.12	40.1	41.02	36.73	32.24	40.51	33.67	34.8	36.182
90%	40.08	34.56	13.5	30.27	37.01	15.13	38.24	33.13	39.67	36.4	31.799

Berdasarkan tabel 5.6, pengujian pengaruh jumlah data latih terhadap hasil akurasi dataset red wine didapatkan jumlah data latih terbaik pada pengujian ini

ketika data latih berjumlah 10% dari data keseluruhan dengan rata-rata akurasi 42.97%.

5.2.3 Pengujian untuk mengetahui pengaruh maksimum epoh terhadap hasil akurasi

Pada pengujian untuk mengetahui pengaruh maksimum epoh terhadap hasil akurasi, diambil nilai minimum *support* dan learning rate yang memiliki hasil akurasi terbaik dari pengujian sebelumnya. Jumlah data latih yang digunakan pada pengujian ini 75% dari jumlah data serta maximum epoh dimulai dengan 1 hingga 1000 dan batas error 10^{-3} . didapatkan hasil pengujian pengaruh *learning rate* pada dataset *red wine* seperti ditampilkan pada tabel 5.7

Tabel 5.7 Tabel pengaruh maksimum epoh terhadap hasil akurasi dataset *red wine*

epoh	Uji1	Uji 2	Uji 3	Uji 4	Uji 5	Uji 6	Uji 7	Uji 8	Uji 9	Uji10	Rata-rata
100	29.15	17.34	32.41	24.12	35.93	49.25	38.19	21.61	50	34.92	33.292
500	49.5	57.54	56.78	54.27	47.74	49.75	37.69	50.25	51.76	52.51	50.779
1000	53.02	55.78	57.04	54.02	52.01	52.76	54.77	54.02	53.77	50	53.719
1600	58.29	57.79	54.52	55.78	56.03	53.77	55.78	56.28	52.51	51.76	55.251
2300	58.29	57.79	54.52	57.04	56.03	52.76	56.53	56.28	50.5	53.27	55.301
3100	58.29	57.79	54.52	57.04	56.03	52.51	56.53	56.28	49.5	53.27	55.176
4000	58.29	57.79	54.52	57.04	56.03	52.51	56.53	56.28	49.5	53.27	55.176
5000	58.29	57.79	54.52	57.04	56.03	52.51	56.53	56.28	49.5	53.27	55.176

Berdasarkan tabel 5.7, pengujian pengaruh maksimum epoh terhadap hasil akurasi dataset *red wine* didapatkan jumlah data latih terbaik pada pengujian ini ketika maksimum epoh 2300 dengan rata-rata akurasi 55.301%.

Sedangkan pada pengujian untuk mengetahui pengaruh maksimum epoh terhadap hasil akurasi dataset *white wine*, didapatkan hasil pengujian pengaruh maksimum epoh pada dataset *white wine* seperti ditampilkan pada tabel 5.8.

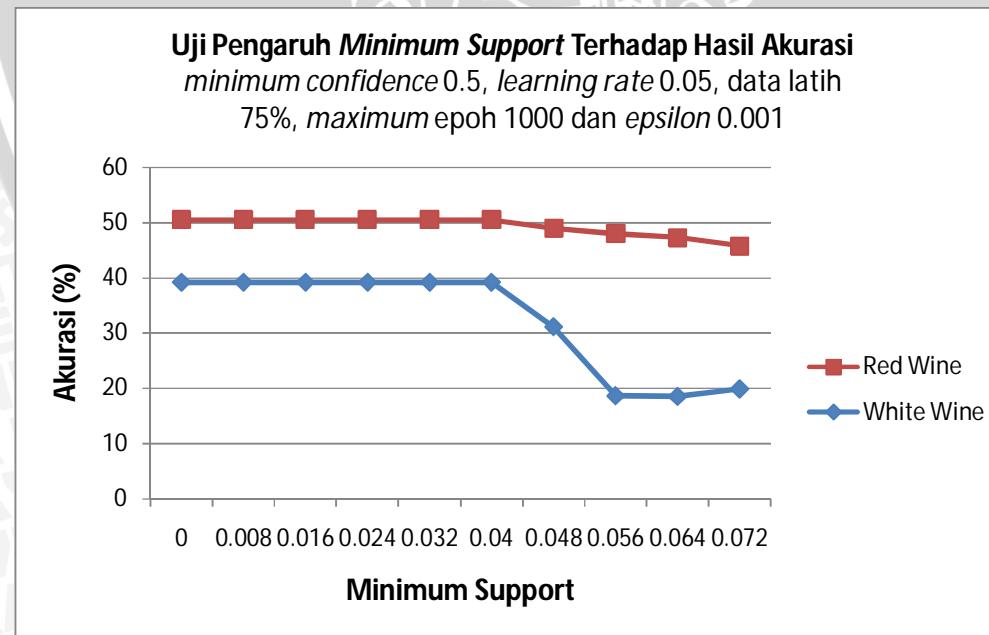
Tabel 5.8 Tabel pengaruh maksimum epoh terhadap hasil akurasi dataset *white wine*

epoh	Uji1	Uji 2	Uji 3	Uji 4	Uji 5	Uji 6	Uji 7	Uji 8	Uji 9	Uji10	Rata-rata
100	28.02	25.65	20.42	27.29	20.42	20.42	25.25	23.37	27.12	18.55	23.651
500	42.08	38.32	41.09	37.99	41.18	41.18	38.73	39.62	35.78	39.38	39.535
1000	39.95	39.05	43.14	37.17	43.06	42.89	38.32	38.48	42.97	39.13	40.416
1600	42.81	41.09	43.71	41.75	43.46	43.63	41.67	41.5	42.08	39.46	42.116
2300	43.71	42.08	43.14	42.4	42.81	42.65	42.32	42.32	40.44	40.93	42.28
3100	45.59	43.55	42.81	43.87	41.58	42.24	42.97	42.57	41.42	42.89	42.949
4000	44.53	44.44	42.4	43.87	42.81	42.24	43.22	43.38	43.87	43.63	43.439
5000	44.53	45.18	42.4	44.28	42.81	42.24	43.22	43.38	40.2	43.63	43.187

Berdasarkan tabel 5.8, pengujian pengaruh maksimum epoh terhadap hasil akurasi dataset red wine didapatkan jumlah data latih terbaik pada pengujian ini ketika maksimum epoh 4000 dengan rata-rata akurasi 43.439%.

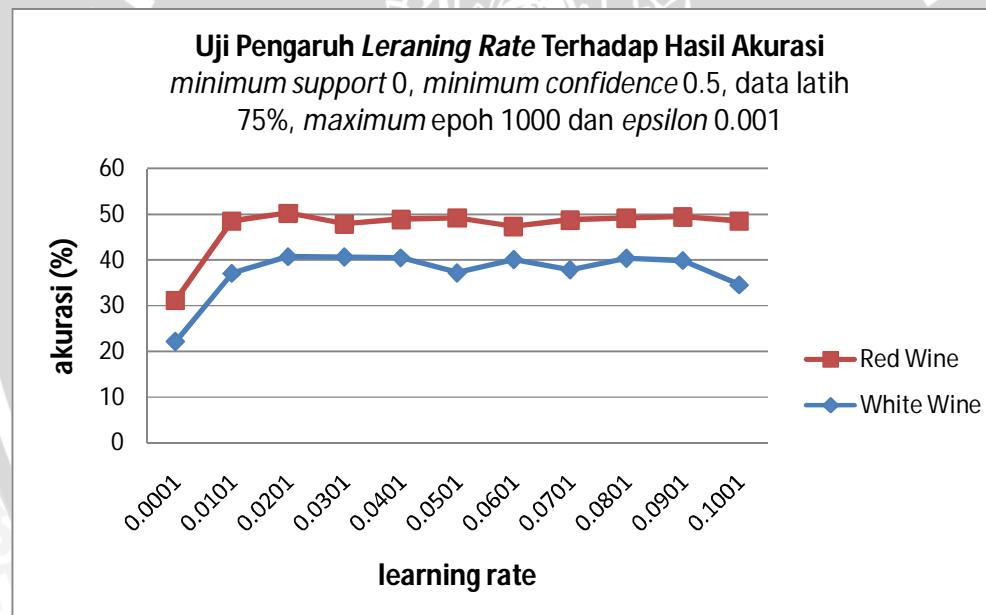
5.3 Analisa Hasil

5.3.1 Analisa hasil pengujian untuk mengetahui pengaruh nilai minimum support dan minimum confidence terhadap hasil akurasi

**Gambar 5.1** Gambar pengaruh minimum *group support* terhadap hasil akurasi

Berdasarkan gambar 5.1 didapatkan bahwa nilai minimum support yang menghasilkan akurasi terbaik pada dataset red wine dan dataset white wine berada pada nilai 0 sampai 0.04. Dengan hasil akurasi yang stabil dari minimum support 0 sampai dengan 0.04 dikarenakan dataset wine quality, red wine maupun white wine tidak memiliki data dengan nilai yang dominan pada setiap atributnya. Dan untuk nilai minimum support lebih dari 0.04, hasil akurasi pada kedua dataset akan menurun drastis. Hal ini dikarenakan karena adanya atribut dengan nilai bobot 0, sehingga mempengaruhi hasil akurasi.

5.3.2 Analisa hasil pengujian untuk mengetahui pengaruh learning rate terhadap hasil akurasi

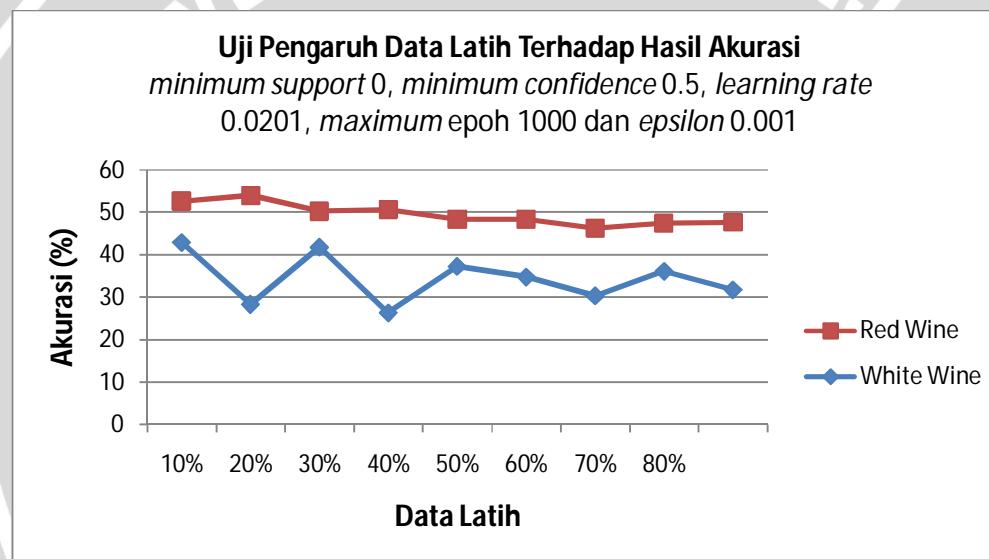


Gambar 5.2 Gambar pengaruh learning rate terhadap hasil akurasi

Berdasarkan gambar 5.2 didapatkan bahwa learning rate yang menghasilkan akurasi terbaik pada dataset wine quality berada pada 0.0201. dan akurasi mulai stabil ketika learning rate lebih dari 0.0101. learning rate kurang dari 0.0101 menyebabkan hasil akurasi yang kurang baik karena dengan learning rate yang kecil, perubahan nilai pada data centroid akan berjalan lambat.

Pada dataset white wine, learning rate dengan hasil akurasi terbaik terletak pada 0.0201. ketika learning rate kurang dari 0.0101 atau lebih dari 0.0901 hasil akurasi akan menurun. Hal ini disebabkan oleh pergeseran optimal pada dataset white wine terletak pada learning rate 0.0201-0.0901. ketika learning rate terlalu kecil, pergeseran pada data centroid lebih kecil. Sedangkan ketika learning rate terlalu besar, pergeseran data centroid akan semakin besar menjauhi optimal.

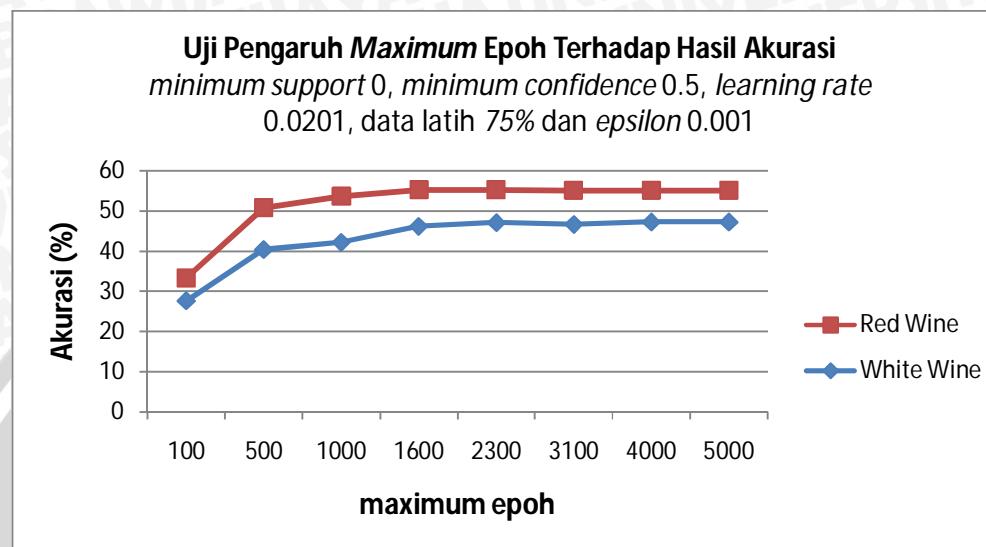
5.3.3 Analisa hasil pengujian untuk mengetahui pengaruh jumlah data latih terhadap hasil akurasi



Gambar 5.3a Gambar pengaruh jumlah data latih terhadap hasil akurasi

Berdasarkan gambar 5.3 didapatkan bahwa hasil dari pengujian pengaruh jumlah data latih menghasilkan akurasi yang tidak stabil atau tidak berpola. Hal ini disebabkan adanya variasi pola data latih dengan data uji yang berbeda jauh sehingga data centroid yang diambil sebagai acuan tidak dapat mewakili pola data uji. Dan kemungkinan terdapat outliers pada data latih maupun data ujinya sehingga hasil akurasi cenderung tidak berpola.

5.3.4 Analisa hasil pengujian untuk mengetahui pengaruh maksimum epoch terhadap hasil akurasi



Gambar 5.4 Gambar pengaruh maksimum epoch terhadap hasil akurasi

Berdasarkan gambar 5.4 didapatkan bahwa semakin besar maksimum epoch, semakin besar pula hasil akurasi. Hal ini dikarenakan semakin besar iterasi yang dilakukan pada proses LVQ, proses pembelajaran yang besar menyebabkan pergeseran centroid menjadi lebih optimal. Pada dataset red wine, hasil akurasi terbaik pada maksimum epoch 2300 dan hasil akurasi mulai stabil ketika maksimum epoch lebih dari 2300.

Dan untuk dataset white wine, hasil akurasi terbaik ketika epoch 5000 dan dimungkinkan hasil akurasi lebih baik ketika epoch lebih dari 5000. Semakin banyak jumlah data latih pada wine quality, dibutuhkan epoch yang lebih besar pula untuk mencapai hasil akurasi yang optimal.

BAB VI

KESIMPULAN DAN SARAN

6.1 Kesimpulan

Dari hasil uji analisis yang dilakukan, dapat diambil kesimpulan, antara lain

1. Metode Learning Vector Quantization Berbasis Asosiasi (LVQBA) dapat diimplementasikan pada klasifikasi kualitas minuman anggur. Penambahan *association rule* digunakan untuk meningkatkan jumlah akurasi yang terdapat pada jumlah *dataset* yang besar. Penentuan bobot yang dilakukan dengan cara menentukan nilai *minimum support* dan *minimum confidence* terlebih dahulu. Nilai *group support* dan *group confidence* yang kurang dari nilai minimumnya, maka dilakukan pemberian bobot bernilai 0 pada atribut tersebut.
2. Penambahan bobot ditambahkan pada perhitungan jarak menggunakan *Euclidean Distance* setelah proses LVQ berakhir. Kelas yang diperoleh berdasarkan jarak terdekat terhadap data centroid yang telah ter-update.
3. Hasil akurasi yang diperoleh LVQBA pada pengujian terhadap *dataset red wine* maupun *white wine* dipengaruhi oleh beberapa hal,
 - a. Nilai *minimum support* yang menghasilkan akurasi terbaik berada antara 0 sampai dengan 0.04 untuk *dataset wine quality*. Lebih dari 0.04, maka hasil akurasi akan cenderung menurun dan tidak optimal.
 - b. Nilai *group confidence* yang sama pada tiap pengujian tidak mempengaruhi hasil akurasi dikarenakan data yang dimiliki oleh *dataset* berupa data bernilai kontinyu dan tidak ada nilai yang dominan pada tiap atribut.
 - c. Semakin kecil nilai *learning rate*, menghasilkan akurasi yang kurang optimal. Hasil akurasi terbaik berada pada *learning rate* lebih dari 0.0201 untuk *dataset wine quality*.
 - d. Pengaruh jumlah data latih tidak mempengaruhi pola *dataset* ketika data *centroid* yang diambil secara acak tanpa adanya aturan tertentu

- e. Semakin besar maksimum epoh mempengaruhi besarnya hasil akurasi, semakin besar maksimum epoh, semakin besar pula hasil akurasinya dan bersifat stabil. Hasil akurasi optimal dan stabil ketika maksimum epoh lebih dari 2300 untuk *dataset red wine* dan maksimum epoh 5000 pada *dataset white wine*, dan dimungkinkan lagi untuk hasil akurasi yang lebih baik ketika maksimum epoh lebih dari 5000.
4. Penambahan *association rule* (metode basis asosiasi) membantu dalam meningkatkan hasil akurasi dengan pemberian bobot di setiap atributnya. Dari penambahan *association rule* pada LVQ, hasil akurasi sedikit bertambah daripada LVQ normal untuk *dataset wine quality*.
5. Hasil akurasi yang didapatkan dari algoritma Learning Vector Quantization Berbasis Asosiasi masih kurang baik dibandingkan dengan penelitian sebelumnya yang menggunakan algoritma KNNBA maupun algoritma SVM dengan kasus yang sama.

6.2 Saran

Beberapa saran untuk pengembangan lebih lanjut, antara lain,

1. Menggunakan metode pengembangan lain yang dapat mengurangi waktu komputasi terhadap dataset yang berjumlah banyak .
2. Dilakukan metode pembobotan selain pembobotan atribut (Basis Asosiasi) terhadap dataset wine quality, misalnya pembobotan berdasarkan sebaran kelas.
3. Adanya proses preprocessing untuk pemilihan data centroid awal pada dataset wine quality sehingga didapatkan hasil akurasi yang lebih optimal.
4. Dimungkinkan penerapan metode Learning Vector Quantization Berbasis Asosiasi pada penelitian terhadap dataset yang lain.

LAMPIRAN**Lampiran 1** Tabel pengujian pengaruh *minimum support* terhadap hasil akurasi dataset *red wine*, *minConf=0.5*, *learning rate = 0.05*, data latih 75%, epoh 1000

Uji	Min Supp.	Min Conf.	Learn. Rate	Data Latih	Jum Latih	Jum Uji	Max Epoh	Centroid 1	Centroid 2	Centroid 3
1	0	0.5	0.05	75%	1201	398	1000	44.97	45.48	44.47
1	0.008	0.5	0.05	75%	1201	398	1000	44.97	45.48	44.47
1	0.016	0.5	0.05	75%	1201	398	1000	44.97	45.48	44.47
1	0.024	0.5	0.05	75%	1201	398	1000	44.97	45.48	44.47
1	0.032	0.5	0.05	75%	1201	398	1000	44.97	45.48	44.47
1	0.04	0.5	0.05	75%	1201	398	1000	44.97	45.48	44.47
1	0.048	0.5	0.05	75%	1201	398	1000	44.97	45.48	44.47
1	0.056	0.5	0.05	75%	1201	398	1000	42.71	43.72	43.72
1	0.064	0.5	0.05	75%	1201	398	1000	46.48	52.51	48.24
1	0.072	0.5	0.05	75%	1201	398	1000	46.48	52.51	48.24
2	0	0.5	0.05	75%	1201	398	1000	46.23	42.46	41.46
2	0.008	0.5	0.05	75%	1201	398	1000	46.23	42.46	41.46
2	0.016	0.5	0.05	75%	1201	398	1000	46.23	42.46	41.46
2	0.024	0.5	0.05	75%	1201	398	1000	46.23	42.46	41.46
2	0.032	0.5	0.05	75%	1201	398	1000	46.23	42.46	41.46
2	0.04	0.5	0.05	75%	1201	398	1000	46.23	42.46	41.46
2	0.048	0.5	0.05	75%	1201	398	1000	46.23	42.46	41.46
2	0.056	0.5	0.05	75%	1201	398	1000	47.74	52.01	42.71
2	0.064	0.5	0.05	75%	1201	398	1000	34.67	38.19	41.96
2	0.072	0.5	0.05	75%	1201	398	1000	14.07	41.96	44.97
3	0	0.5	0.05	75%	1201	398	1000	37.44	39.2	40.95
3	0.008	0.5	0.05	75%	1201	398	1000	37.44	39.2	40.95
3	0.016	0.5	0.05	75%	1201	398	1000	37.44	39.2	40.95
3	0.024	0.5	0.05	75%	1201	398	1000	37.44	39.2	40.95
3	0.032	0.5	0.05	75%	1201	398	1000	37.44	39.2	40.95
3	0.04	0.5	0.05	75%	1201	398	1000	37.44	39.2	40.95
3	0.048	0.5	0.05	75%	1201	398	1000	44.22	45.23	43.72
3	0.056	0.5	0.05	75%	1201	398	1000	44.22	45.23	43.72
3	0.064	0.5	0.05	75%	1201	398	1000	41.46	44.97	41.71
3	0.072	0.5	0.05	75%	1201	398	1000	41.46	44.97	41.71
4	0	0.5	0.05	75%	1201	398	1000	50.25	48.99	49.5
4	0.008	0.5	0.05	75%	1201	398	1000	50.25	48.99	49.5
4	0.016	0.5	0.05	75%	1201	398	1000	50.25	48.99	49.5
4	0.024	0.5	0.05	75%	1201	398	1000	50.25	48.99	49.5
4	0.032	0.5	0.05	75%	1201	398	1000	50.25	48.99	49.5
4	0.04	0.5	0.05	75%	1201	398	1000	50.25	48.99	49.5
4	0.048	0.5	0.05	75%	1201	398	1000	50.25	48.99	49.5
4	0.056	0.5	0.05	75%	1201	398	1000	43.72	47.49	39.45
4	0.064	0.5	0.05	75%	1201	398	1000	37.44	44.72	9.05
4	0.072	0.5	0.05	75%	1201	398	1000	37.44	44.72	9.05
5	0	0.5	0.05	75%	1201	398	1000	46.73	52.01	45.98
5	0.008	0.5	0.05	75%	1201	398	1000	46.73	52.01	45.98
5	0.016	0.5	0.05	75%	1201	398	1000	46.73	52.01	45.98
5	0.024	0.5	0.05	75%	1201	398	1000	46.73	52.01	45.98
5	0.032	0.5	0.05	75%	1201	398	1000	46.73	52.01	45.98
5	0.04	0.5	0.05	75%	1201	398	1000	46.73	52.01	45.98
5	0.048	0.5	0.05	75%	1201	398	1000	46.73	52.01	45.98
5	0.056	0.5	0.05	75%	1201	398	1000	35.68	37.44	40.95
5	0.064	0.5	0.05	75%	1201	398	1000	43.47	46.98	34.17

5	0.072	0.5	0.05	75%	1201	398	1000	45.23	39.7	48.24
6	0	0.5	0.05	75%	1201	398	1000	38.94	36.43	37.69
6	0.008	0.5	0.05	75%	1201	398	1000	38.94	36.43	37.69
6	0.016	0.5	0.05	75%	1201	398	1000	38.94	36.43	37.69
6	0.024	0.5	0.05	75%	1201	398	1000	38.94	36.43	37.69
6	0.032	0.5	0.05	75%	1201	398	1000	38.94	36.43	37.69
6	0.04	0.5	0.05	75%	1201	398	1000	38.94	36.43	37.69
6	0.048	0.5	0.05	75%	1201	398	1000	38.94	36.43	37.69
6	0.056	0.5	0.05	75%	1201	398	1000	38.94	44.97	32.66
6	0.064	0.5	0.05	75%	1201	398	1000	42.46	44.72	34.92
6	0.072	0.5	0.05	75%	1201	398	1000	44.22	53.77	46.23
7	0	0.5	0.05	75%	1201	398	1000	52.26	47.24	46.73
7	0.008	0.5	0.05	75%	1201	398	1000	52.26	47.24	46.73
7	0.016	0.5	0.05	75%	1201	398	1000	52.26	47.24	46.73
7	0.024	0.5	0.05	75%	1201	398	1000	52.26	47.24	46.73
7	0.032	0.5	0.05	75%	1201	398	1000	52.26	47.24	46.73
7	0.04	0.5	0.05	75%	1201	398	1000	52.26	47.24	46.73
7	0.048	0.5	0.05	75%	1201	398	1000	52.51	51.26	50.25
7	0.056	0.5	0.05	75%	1201	398	1000	52.51	51.26	50.25
7	0.064	0.5	0.05	75%	1201	398	1000	55.53	54.02	55.28
7	0.072	0.5	0.05	75%	1201	398	1000	55.53	54.02	55.28
8	0	0.5	0.05	75%	1201	398	1000	45.98	46.98	46.73
8	0.008	0.5	0.05	75%	1201	398	1000	45.98	46.98	46.73
8	0.016	0.5	0.05	75%	1201	398	1000	45.98	46.98	46.73
8	0.024	0.5	0.05	75%	1201	398	1000	45.98	46.98	46.73
8	0.032	0.5	0.05	75%	1201	398	1000	45.98	46.98	46.73
8	0.04	0.5	0.05	75%	1201	398	1000	45.98	46.98	46.73
8	0.048	0.5	0.05	75%	1201	398	1000	45.98	46.98	46.73
8	0.056	0.5	0.05	75%	1201	398	1000	42.71	44.47	47.74
8	0.064	0.5	0.05	75%	1201	398	1000	22.86	43.97	29.9
8	0.072	0.5	0.05	75%	1201	398	1000	22.86	43.97	29.9
9	0	0.5	0.05	75%	1201	398	1000	44.97	47.74	45.23
9	0.008	0.5	0.05	75%	1201	398	1000	44.97	47.74	45.23
9	0.016	0.5	0.05	75%	1201	398	1000	44.97	47.74	45.23
9	0.024	0.5	0.05	75%	1201	398	1000	44.97	47.74	45.23
9	0.032	0.5	0.05	75%	1201	398	1000	44.97	47.74	45.23
9	0.04	0.5	0.05	75%	1201	398	1000	44.97	47.74	45.23
9	0.048	0.5	0.05	75%	1201	398	1000	44.97	47.74	45.23
9	0.056	0.5	0.05	75%	1201	398	1000	38.69	48.49	43.97
9	0.064	0.5	0.05	75%	1201	398	1000	43.97	48.99	48.99
9	0.072	0.5	0.05	75%	1201	398	1000	43.97	48.99	48.99
10	0	0.5	0.05	75%	1201	398	1000	47.49	44.72	51.01
10	0.008	0.5	0.05	75%	1201	398	1000	47.49	44.72	51.01
10	0.016	0.5	0.05	75%	1201	398	1000	47.49	44.72	51.01
10	0.024	0.5	0.05	75%	1201	398	1000	47.49	44.72	51.01
10	0.032	0.5	0.05	75%	1201	398	1000	47.49	44.72	51.01
10	0.04	0.5	0.05	75%	1201	398	1000	47.49	44.72	51.01
10	0.048	0.5	0.05	75%	1201	398	1000	47.49	44.72	51.01
10	0.056	0.5	0.05	75%	1201	398	1000	36.68	44.22	40.95
10	0.064	0.5	0.05	75%	1201	398	1000	47.99	43.47	47.49
10	0.072	0.5	0.05	75%	1201	398	1000	47.99	43.47	47.49
11	0	0.5	0.05	75%	1201	398	1000	56.53	50.25	53.27
11	0.008	0.5	0.05	75%	1201	398	1000	56.53	50.25	53.27
11	0.016	0.5	0.05	75%	1201	398	1000	56.53	50.25	53.27
11	0.024	0.5	0.05	75%	1201	398	1000	56.53	50.25	53.27

11	0.032	0.5	0.05	75%	1201	398	1000	56.53	50.25	53.27
11	0.04	0.5	0.05	75%	1201	398	1000	56.53	50.25	53.27
11	0.048	0.5	0.05	75%	1201	398	1000	43.47	49.5	44.22
11	0.056	0.5	0.05	75%	1201	398	1000	44.72	43.22	41.96
11	0.064	0.5	0.05	75%	1201	398	1000	42.46	43.47	41.96
11	0.072	0.5	0.05	75%	1201	398	1000	42.46	43.47	41.96
12	0	0.5	0.05	75%	1201	398	1000	32.41	44.97	46.98
12	0.008	0.5	0.05	75%	1201	398	1000	32.41	44.97	46.98
12	0.016	0.5	0.05	75%	1201	398	1000	32.41	44.97	46.98
12	0.024	0.5	0.05	75%	1201	398	1000	32.41	44.97	46.98
12	0.032	0.5	0.05	75%	1201	398	1000	32.41	44.97	46.98
12	0.04	0.5	0.05	75%	1201	398	1000	32.41	44.97	46.98
12	0.048	0.5	0.05	75%	1201	398	1000	29.15	48.24	48.49
12	0.056	0.5	0.05	75%	1201	398	1000	43.72	43.97	47.24
12	0.064	0.5	0.05	75%	1201	398	1000	44.97	43.22	47.24
12	0.072	0.5	0.05	75%	1201	398	1000	40.45	37.69	46.98



Lampiran 2 Tabel pengujian pengaruh *minimum support* terhadap hasil akurasi dataset *white wine*, *minConf*=0.5, *learning rate* = 0.05, data latih 75%, epoh 1000

Uji	Min Supp.	Min Conf.	Learn. Rate	Data Latih	Jum Latih	Jum Uji	Max Epoh	Centroid 1	Centroid 2	Centroid 3
1	0	0.5	0.05	75%	3674	1224	1000	40.52	40.36	39.54
1	0.008	0.5	0.05	75%	3674	1224	1000	40.52	40.36	39.54
1	0.016	0.5	0.05	75%	3674	1224	1000	40.52	40.36	39.54
1	0.024	0.5	0.05	75%	3674	1224	1000	40.52	40.36	39.54
1	0.032	0.5	0.05	75%	3674	1224	1000	40.52	40.36	39.54
1	0.04	0.5	0.05	75%	3674	1224	1000	40.52	40.36	39.54
1	0.048	0.5	0.05	75%	3674	1224	1000	31.29	30.23	26.31
1	0.056	0.5	0.05	75%	3674	1224	1000	7.27	9.97	10.54
1	0.064	0.5	0.05	75%	3674	1224	1000	35.87	35.13	25.65
1	0.072	0.5	0.05	75%	3674	1224	1000	35.87	35.13	25.65
2	0	0.5	0.05	75%	3674	1224	1000	38.24	38.64	38.32
2	0.008	0.5	0.05	75%	3674	1224	1000	38.24	38.64	38.32
2	0.016	0.5	0.05	75%	3674	1224	1000	38.24	38.64	38.32
2	0.024	0.5	0.05	75%	3674	1224	1000	38.24	38.64	38.32
2	0.032	0.5	0.05	75%	3674	1224	1000	38.24	38.64	38.32
2	0.04	0.5	0.05	75%	3674	1224	1000	38.24	38.64	38.32
2	0.048	0.5	0.05	75%	3674	1224	1000	30.23	32.52	32.27
2	0.056	0.5	0.05	75%	3674	1224	1000	32.35	32.03	32.11
2	0.064	0.5	0.05	75%	3674	1224	1000	18.14	18.38	18.3
2	0.072	0.5	0.05	75%	3674	1224	1000	18.14	18.38	18.3
3	0	0.5	0.05	75%	3674	1224	1000	13.89	16.58	6.94
3	0.008	0.5	0.05	75%	3674	1224	1000	13.89	16.58	6.94
3	0.016	0.5	0.05	75%	3674	1224	1000	13.89	16.58	6.94
3	0.024	0.5	0.05	75%	3674	1224	1000	13.89	16.58	6.94
3	0.032	0.5	0.05	75%	3674	1224	1000	13.89	16.58	6.94
3	0.04	0.5	0.05	75%	3674	1224	1000	13.89	16.58	6.94
3	0.048	0.5	0.05	75%	3674	1224	1000	6.86	7.19	5.56
3	0.056	0.5	0.05	75%	3674	1224	1000	6.13	6.37	6.78
3	0.064	0.5	0.05	75%	3674	1224	1000	6.54	6.54	6.54
3	0.072	0.5	0.05	75%	3674	1224	1000	6.54	6.54	6.54
4	0	0.5	0.05	75%	3674	1224	1000	18.38	20.1	14.38
4	0.008	0.5	0.05	75%	3674	1224	1000	18.38	20.1	14.38
4	0.016	0.5	0.05	75%	3674	1224	1000	18.38	20.1	14.38
4	0.024	0.5	0.05	75%	3674	1224	1000	18.38	20.1	14.38
4	0.032	0.5	0.05	75%	3674	1224	1000	18.38	20.1	14.38
4	0.04	0.5	0.05	75%	3674	1224	1000	18.38	20.1	14.38
4	0.048	0.5	0.05	75%	3674	1224	1000	27.29	28.92	27.12
4	0.056	0.5	0.05	75%	3674	1224	1000	18.87	18.87	18.14
4	0.064	0.5	0.05	75%	3674	1224	1000	7.6	6.13	7.43
4	0.072	0.5	0.05	75%	3674	1224	1000	19.69	5.15	12.99
5	0	0.5	0.05	75%	3674	1224	1000	29.41	38.73	6.94
5	0.008	0.5	0.05	75%	3674	1224	1000	29.41	38.73	6.94
5	0.016	0.5	0.05	75%	3674	1224	1000	29.41	38.73	6.94
5	0.024	0.5	0.05	75%	3674	1224	1000	29.41	38.73	6.94
5	0.032	0.5	0.05	75%	3674	1224	1000	29.41	38.73	6.94
5	0.04	0.5	0.05	75%	3674	1224	1000	29.41	38.73	6.94
5	0.048	0.5	0.05	75%	3674	1224	1000	5.31	31.78	4.58
5	0.056	0.5	0.05	75%	3674	1224	1000	4.49	13.97	2.53
5	0.064	0.5	0.05	75%	3674	1224	1000	4.9	9.64	1.14
5	0.072	0.5	0.05	75%	3674	1224	1000	6.13	6.62	3.84
6	0	0.5	0.05	75%	3674	1224	1000	21.41	9.07	12.25

6	0.008	0.5	0.05	75%	3674	1224	1000	21.41	9.07	12.25
6	0.016	0.5	0.05	75%	3674	1224	1000	21.41	9.07	12.25
6	0.024	0.5	0.05	75%	3674	1224	1000	21.41	9.07	12.25
6	0.032	0.5	0.05	75%	3674	1224	1000	21.41	9.07	12.25
6	0.04	0.5	0.05	75%	3674	1224	1000	21.41	9.07	12.25
6	0.048	0.5	0.05	75%	3674	1224	1000	34.89	16.42	6.29
6	0.056	0.5	0.05	75%	3674	1224	1000	8.42	6.78	7.76
6	0.064	0.5	0.05	75%	3674	1224	1000	8.09	8.09	4.66
6	0.072	0.5	0.05	75%	3674	1224	1000	7.43	7.76	4.9
7	0	0.5	0.05	75%	3674	1224	1000	33.33	24.02	32.52
7	0.008	0.5	0.05	75%	3674	1224	1000	33.33	24.02	32.52
7	0.016	0.5	0.05	75%	3674	1224	1000	33.33	24.02	32.52
7	0.024	0.5	0.05	75%	3674	1224	1000	33.33	24.02	32.52
7	0.032	0.5	0.05	75%	3674	1224	1000	33.33	24.02	32.52
7	0.04	0.5	0.05	75%	3674	1224	1000	33.33	24.02	32.52
7	0.048	0.5	0.05	75%	3674	1224	1000	30.47	26.96	26.96
7	0.056	0.5	0.05	75%	3674	1224	1000	6.29	5.96	6.29
7	0.064	0.5	0.05	75%	3674	1224	1000	3.43	1.8	6.37
7	0.072	0.5	0.05	75%	3674	1224	1000	5.31	4.49	4.9
8	0	0.5	0.05	75%	3674	1224	1000	27.94	15.11	10.7
8	0.008	0.5	0.05	75%	3674	1224	1000	27.94	15.11	10.7
8	0.016	0.5	0.05	75%	3674	1224	1000	27.94	15.11	10.7
8	0.024	0.5	0.05	75%	3674	1224	1000	27.94	15.11	10.7
8	0.032	0.5	0.05	75%	3674	1224	1000	27.94	15.11	10.7
8	0.04	0.5	0.05	75%	3674	1224	1000	27.94	15.11	10.7
8	0.048	0.5	0.05	75%	3674	1224	1000	37.91	38.89	38.73
8	0.056	0.5	0.05	75%	3674	1224	1000	39.05	5.15	18.95
8	0.064	0.5	0.05	75%	3674	1224	1000	24.18	2.86	18.14
8	0.072	0.5	0.05	75%	3674	1224	1000	4.17	3.59	29
9	0	0.5	0.05	75%	3674	1224	1000	24.02	5.39	6.29
9	0.008	0.5	0.05	75%	3674	1224	1000	24.02	5.39	6.29
9	0.016	0.5	0.05	75%	3674	1224	1000	24.02	5.39	6.29
9	0.024	0.5	0.05	75%	3674	1224	1000	24.02	5.39	6.29
9	0.032	0.5	0.05	75%	3674	1224	1000	24.02	5.39	6.29
9	0.04	0.5	0.05	75%	3674	1224	1000	24.02	5.39	6.29
9	0.048	0.5	0.05	75%	3674	1224	1000	21.41	28.02	17.89
9	0.056	0.5	0.05	75%	3674	1224	1000	8.66	6.37	8.66
9	0.064	0.5	0.05	75%	3674	1224	1000	19.93	2.86	2.86
9	0.072	0.5	0.05	75%	3674	1224	1000	19.93	2.86	2.86
10	0	0.5	0.05	75%	3674	1224	1000	40.6	35.78	37.09
10	0.008	0.5	0.05	75%	3674	1224	1000	40.6	35.78	37.09
10	0.016	0.5	0.05	75%	3674	1224	1000	40.6	35.78	37.09
10	0.024	0.5	0.05	75%	3674	1224	1000	40.6	35.78	37.09
10	0.032	0.5	0.05	75%	3674	1224	1000	40.6	35.78	37.09
10	0.04	0.5	0.05	75%	3674	1224	1000	40.6	35.78	37.09
10	0.048	0.5	0.05	75%	3674	1224	1000	17.81	25.74	26.96
10	0.056	0.5	0.05	75%	3674	1224	1000	32.68	32.68	6.78
10	0.064	0.5	0.05	75%	3674	1224	1000	5.23	5.31	5.31
10	0.072	0.5	0.05	75%	3674	1224	1000	21.81	7.52	7.52
11	0	0.5	0.05	75%	3674	1224	1000	38.48	38.15	38.89
11	0.008	0.5	0.05	75%	3674	1224	1000	38.48	38.15	38.89
11	0.016	0.5	0.05	75%	3674	1224	1000	38.48	38.15	38.89
11	0.024	0.5	0.05	75%	3674	1224	1000	38.48	38.15	38.89
11	0.032	0.5	0.05	75%	3674	1224	1000	38.48	38.15	38.89
11	0.04	0.5	0.05	75%	3674	1224	1000	38.48	38.15	38.89

11	0.048	0.5	0.05	75%	3674	1224	1000	39.54	37.5	39.87
11	0.056	0.5	0.05	75%	3674	1224	1000	9.64	7.84	6.37
11	0.064	0.5	0.05	75%	3674	1224	1000	9.72	9.89	9.56
11	0.072	0.5	0.05	75%	3674	1224	1000	9.72	9.89	9.56
12	0	0.5	0.05	75%	3674	1224	1000	15.77	6.05	18.14
12	0.008	0.5	0.05	75%	3674	1224	1000	15.77	6.05	18.14
12	0.016	0.5	0.05	75%	3674	1224	1000	15.77	6.05	18.14
12	0.024	0.5	0.05	75%	3674	1224	1000	15.77	6.05	18.14
12	0.032	0.5	0.05	75%	3674	1224	1000	15.77	6.05	18.14
12	0.04	0.5	0.05	75%	3674	1224	1000	15.77	6.05	18.14
12	0.048	0.5	0.05	75%	3674	1224	1000	5.8	5.72	5.8
12	0.056	0.5	0.05	75%	3674	1224	1000	6.62	9.89	4.74
12	0.064	0.5	0.05	75%	3674	1224	1000	5.39	9.07	5.39
12	0.072	0.5	0.05	75%	3674	1224	1000	4.49	4.49	6.94



Lampiran 3 Tabel pengujian pengaruh *learning rate* terhadap hasil akurasi dataset red wine, minSupp=0, minConf=0.5, data latih 75%, epoch 1000

Uji	Min Supp.	Min Conf.	Learn. Rate	Data Latih	Jum Latih	Jum Uji	Max Epoh	Centroid 1	Centroid 2	Centroid 3
1	0	0.5	0.0001	75%	1201	398	1000	29.65	27.89	32.91
1	0	0.5	0.0101	75%	1201	398	1000	47.24	47.24	54.02
1	0	0.5	0.0201	75%	1201	398	1000	50.25	50.75	61.56
1	0	0.5	0.0301	75%	1201	398	1000	48.24	49.5	46.48
1	0	0.5	0.0401	75%	1201	398	1000	50	49.5	60.55
1	0	0.5	0.0501	75%	1201	398	1000	46.98	49.25	61.56
1	0	0.5	0.0601	75%	1201	398	1000	49.5	47.49	46.48
1	0	0.5	0.0701	75%	1201	398	1000	45.98	47.49	54.27
1	0	0.5	0.0801	75%	1201	398	1000	47.24	47.99	61.06
1	0	0.5	0.0901	75%	1201	398	1000	47.49	48.49	57.29
1	0	0.5	0.1001	75%	1201	398	1000	48.99	48.24	61.81
2	0	0.5	0.0001	75%	1201	398	1000	35.43	33.42	42.21
2	0	0.5	0.0101	75%	1201	398	1000	44.72	44.97	46.73
2	0	0.5	0.0201	75%	1201	398	1000	46.48	44.72	46.73
2	0	0.5	0.0301	75%	1201	398	1000	45.23	45.48	44.72
2	0	0.5	0.0401	75%	1201	398	1000	45.73	45.48	44.97
2	0	0.5	0.0501	75%	1201	398	1000	47.99	42.46	47.24
2	0	0.5	0.0601	75%	1201	398	1000	49.75	45.23	44.47
2	0	0.5	0.0701	75%	1201	398	1000	47.49	44.22	47.24
2	0	0.5	0.0801	75%	1201	398	1000	48.74	43.22	42.21
2	0	0.5	0.0901	75%	1201	398	1000	43.47	45.98	46.23
2	0	0.5	0.1001	75%	1201	398	1000	46.48	44.47	45.98
3	0	0.5	0.0001	75%	1201	398	1000	20.6	37.19	39.2
3	0	0.5	0.0101	75%	1201	398	1000	53.52	55.03	47.49
3	0	0.5	0.0201	75%	1201	398	1000	44.47	54.02	55.03
3	0	0.5	0.0301	75%	1201	398	1000	45.98	47.24	56.03
3	0	0.5	0.0401	75%	1201	398	1000	47.74	48.74	49.75
3	0	0.5	0.0501	75%	1201	398	1000	51.51	52.51	53.27
3	0	0.5	0.0601	75%	1201	398	1000	48.49	51.26	50.5
3	0	0.5	0.0701	75%	1201	398	1000	44.97	51.76	51.26
3	0	0.5	0.0801	75%	1201	398	1000	46.98	49.75	53.02
3	0	0.5	0.0901	75%	1201	398	1000	45.73	55.03	55.03
3	0	0.5	0.1001	75%	1201	398	1000	41.96	54.27	50.25
4	0	0.5	0.0001	75%	1201	398	1000	32.91	17.84	22.61
4	0	0.5	0.0101	75%	1201	398	1000	45.48	48.99	48.49
4	0	0.5	0.0201	75%	1201	398	1000	49.75	48.74	48.99
4	0	0.5	0.0301	75%	1201	398	1000	50.25	46.73	35.18
4	0	0.5	0.0401	75%	1201	398	1000	49.5	47.24	46.98
4	0	0.5	0.0501	75%	1201	398	1000	46.48	46.73	45.73
4	0	0.5	0.0601	75%	1201	398	1000	46.23	47.24	36.18
4	0	0.5	0.0701	75%	1201	398	1000	46.48	46.73	46.23
4	0	0.5	0.0801	75%	1201	398	1000	45.23	46.48	46.48
4	0	0.5	0.0901	75%	1201	398	1000	50.25	49.5	41.46
4	0	0.5	0.1001	75%	1201	398	1000	49.25	49.25	45.48
5	0	0.5	0.0001	75%	1201	398	1000	17.09	25.38	24.62
5	0	0.5	0.0101	75%	1201	398	1000	40.2	39.7	40.95
5	0	0.5	0.0201	75%	1201	398	1000	40.45	32.66	39.45
5	0	0.5	0.0301	75%	1201	398	1000	40.45	38.69	42.21
5	0	0.5	0.0401	75%	1201	398	1000	39.95	39.7	39.7
5	0	0.5	0.0501	75%	1201	398	1000	38.94	41.46	42.96
5	0	0.5	0.0601	75%	1201	398	1000	42.46	41.46	41.96

5	0	0.5	0.0701	75%	1201	398	1000	39.95	40.45	42.21
5	0	0.5	0.0801	75%	1201	398	1000	40.95	35.18	38.19
5	0	0.5	0.0901	75%	1201	398	1000	40.2	34.92	38.19
5	0	0.5	0.1001	75%	1201	398	1000	38.44	35.18	38.19
6	0	0.5	0.0001	75%	1201	398	1000	26.13	27.64	16.33
6	0	0.5	0.0101	75%	1201	398	1000	40.45	48.24	47.49
6	0	0.5	0.0201	75%	1201	398	1000	37.69	46.98	47.99
6	0	0.5	0.0301	75%	1201	398	1000	44.72	47.24	47.99
6	0	0.5	0.0401	75%	1201	398	1000	44.22	47.24	45.73
6	0	0.5	0.0501	75%	1201	398	1000	44.47	48.99	46.98
6	0	0.5	0.0601	75%	1201	398	1000	44.47	48.99	44.72
6	0	0.5	0.0701	75%	1201	398	1000	44.47	48.49	44.72
6	0	0.5	0.0801	75%	1201	398	1000	44.72	47.74	45.23
6	0	0.5	0.0901	75%	1201	398	1000	44.72	47.24	45.23
6	0	0.5	0.1001	75%	1201	398	1000	44.72	47.99	45.73
7	0	0.5	0.0001	75%	1201	398	1000	31.41	37.19	22.61
7	0	0.5	0.0101	75%	1201	398	1000	57.04	37.44	53.52
7	0	0.5	0.0201	75%	1201	398	1000	47.49	46.23	43.97
7	0	0.5	0.0301	75%	1201	398	1000	46.73	38.44	44.47
7	0	0.5	0.0401	75%	1201	398	1000	46.48	43.22	55.53
7	0	0.5	0.0501	75%	1201	398	1000	46.23	46.98	45.48
7	0	0.5	0.0601	75%	1201	398	1000	46.73	44.47	43.97
7	0	0.5	0.0701	75%	1201	398	1000	47.74	45.48	42.71
7	0	0.5	0.0801	75%	1201	398	1000	47.74	46.23	41.96
7	0	0.5	0.0901	75%	1201	398	1000	46.23	45.23	45.48
7	0	0.5	0.1001	75%	1201	398	1000	44.22	45.23	46.23
8	0	0.5	0.0001	75%	1201	398	1000	25.13	24.37	34.17
8	0	0.5	0.0101	75%	1201	398	1000	45.98	47.24	44.72
8	0	0.5	0.0201	75%	1201	398	1000	44.97	46.23	43.22
8	0	0.5	0.0301	75%	1201	398	1000	36.68	46.23	42.96
8	0	0.5	0.0401	75%	1201	398	1000	28.89	47.49	44.97
8	0	0.5	0.0501	75%	1201	398	1000	28.89	46.48	42.21
8	0	0.5	0.0601	75%	1201	398	1000	45.48	47.24	25.13
8	0	0.5	0.0701	75%	1201	398	1000	44.22	48.24	44.72
8	0	0.5	0.0801	75%	1201	398	1000	44.22	47.24	45.48
8	0	0.5	0.0901	75%	1201	398	1000	45.23	46.73	45.48
8	0	0.5	0.1001	75%	1201	398	1000	45.23	46.48	44.97
9	0	0.5	0.0001	75%	1201	398	1000	35.43	9.55	18.59
9	0	0.5	0.0101	75%	1201	398	1000	46.73	50.5	56.53
9	0	0.5	0.0201	75%	1201	398	1000	53.52	44.72	45.73
9	0	0.5	0.0301	75%	1201	398	1000	44.72	51.26	45.23
9	0	0.5	0.0401	75%	1201	398	1000	43.97	43.72	44.22
9	0	0.5	0.0501	75%	1201	398	1000	48.99	45.48	53.02
9	0	0.5	0.0601	75%	1201	398	1000	45.73	47.74	47.49
9	0	0.5	0.0701	75%	1201	398	1000	49.25	55.78	45.48
9	0	0.5	0.0801	75%	1201	398	1000	44.22	47.49	50
9	0	0.5	0.0901	75%	1201	398	1000	53.02	45.73	48.49
9	0	0.5	0.1001	75%	1201	398	1000	45.48	48.99	47.74
10	0	0.5	0.0001	75%	1201	398	1000	27.89	22.11	25.13
10	0	0.5	0.0101	75%	1201	398	1000	43.47	45.23	43.47
10	0	0.5	0.0201	75%	1201	398	1000	42.21	44.47	42.71
10	0	0.5	0.0301	75%	1201	398	1000	41.96	46.98	43.22
10	0	0.5	0.0401	75%	1201	398	1000	44.47	44.97	44.97
10	0	0.5	0.0501	75%	1201	398	1000	46.23	43.72	41.21
10	0	0.5	0.0601	75%	1201	398	1000	45.48	44.47	41.46

10	0	0.5	0.0701	75%	1201	398	1000	45.23	43.72	43.97
10	0	0.5	0.0801	75%	1201	398	1000	45.98	42.46	43.72
10	0	0.5	0.0901	75%	1201	398	1000	44.47	42.71	44.47
10	0	0.5	0.1001	75%	1201	398	1000	43.72	44.22	44.22
11	0	0.5	0.0001	75%	1201	398	1000	15.83	18.59	25.88
11	0	0.5	0.0101	75%	1201	398	1000	49.5	45.98	46.73
11	0	0.5	0.0201	75%	1201	398	1000	45.98	51.26	45.98
11	0	0.5	0.0301	75%	1201	398	1000	41.96	42.96	46.73
11	0	0.5	0.0401	75%	1201	398	1000	41.71	43.97	47.74
11	0	0.5	0.0501	75%	1201	398	1000	46.98	43.22	47.24
11	0	0.5	0.0601	75%	1201	398	1000	49.75	44.22	47.74
11	0	0.5	0.0701	75%	1201	398	1000	46.23	41.96	49.25
11	0	0.5	0.0801	75%	1201	398	1000	48.99	46.23	51.26
11	0	0.5	0.0901	75%	1201	398	1000	49.25	41.96	49.75
11	0	0.5	0.1001	75%	1201	398	1000	47.99	46.48	48.24
12	0	0.5	0.0001	75%	1201	398	1000	37.44	21.36	26.63
12	0	0.5	0.0101	75%	1201	398	1000	44.22	47.49	48.49
12	0	0.5	0.0201	75%	1201	398	1000	44.47	46.73	49.75
12	0	0.5	0.0301	75%	1201	398	1000	44.47	43.47	49.75
12	0	0.5	0.0401	75%	1201	398	1000	44.47	41.46	50.5
12	0	0.5	0.0501	75%	1201	398	1000	46.73	40.95	45.48
12	0	0.5	0.0601	75%	1201	398	1000	44.72	42.21	44.97
12	0	0.5	0.0701	75%	1201	398	1000	44.72	45.73	45.23
12	0	0.5	0.0801	75%	1201	398	1000	44.22	45.48	45.48
12	0	0.5	0.0901	75%	1201	398	1000	43.97	40.7	45.23
12	0	0.5	0.1001	75%	1201	398	1000	49.75	45.98	45.48

Lampiran 4 Tabel pengujian pengaruh *learning rate* terhadap hasil akurasi dataset *white wine*, minSupp=0, minConf=0.5, data latih 75%, epoch 1000

Uji	Min Supp.	Min Conf.	Learn. Rate	Data Latih	Jum Latih	Jum Uji	Max Epoh	Centroid 1	Centroid 2	Centroid 3
1	0	0.5	0.0001	75%	3674	1224	1000	22.39	16.99	16.75
1	0	0.5	0.0101	75%	3674	1224	1000	41.09	32.43	38.89
1	0	0.5	0.0201	75%	3674	1224	1000	40.77	40.36	40.6
1	0	0.5	0.0301	75%	3674	1224	1000	40.69	41.34	40.77
1	0	0.5	0.0401	75%	3674	1224	1000	40.52	41.09	40.36
1	0	0.5	0.0501	75%	3674	1224	1000	40.44	6.45	40.44
1	0	0.5	0.0601	75%	3674	1224	1000	40.69	41.09	40.44
1	0	0.5	0.0701	75%	3674	1224	1000	40.28	40.69	41.01
1	0	0.5	0.0801	75%	3674	1224	1000	40.6	40.77	40.52
1	0	0.5	0.0901	75%	3674	1224	1000	40.44	40.77	40.44
1	0	0.5	0.1001	75%	3674	1224	1000	40.28	40.44	41.01
2	0	0.5	0.0001	75%	3674	1224	1000	33.99	29.82	29.9
2	0	0.5	0.0101	75%	3674	1224	1000	26.55	24.18	4.66
2	0	0.5	0.0201	75%	3674	1224	1000	6.62	10.62	5.07
2	0	0.5	0.0301	75%	3674	1224	1000	21.9	4	6.7
2	0	0.5	0.0401	75%	3674	1224	1000	9.56	4.08	4.74
2	0	0.5	0.0501	75%	3674	1224	1000	4.33	4.66	4.66
2	0	0.5	0.0601	75%	3674	1224	1000	7.43	4.66	4.66
2	0	0.5	0.0701	75%	3674	1224	1000	14.13	4.66	4.66
2	0	0.5	0.0801	75%	3674	1224	1000	15.93	4.33	4.49
2	0	0.5	0.0901	75%	3674	1224	1000	4.33	4.17	4.74
2	0	0.5	0.1001	75%	3674	1224	1000	14.87	4.17	4.33
3	0	0.5	0.0001	75%	3674	1224	1000	22.79	27.04	31.37
3	0	0.5	0.0101	75%	3674	1224	1000	24.92	32.68	32.27
3	0	0.5	0.0201	75%	3674	1224	1000	24.02	33.58	26.31
3	0	0.5	0.0301	75%	3674	1224	1000	27.7	32.92	32.35
3	0	0.5	0.0401	75%	3674	1224	1000	32.84	32.92	32.68
3	0	0.5	0.0501	75%	3674	1224	1000	32.68	32.6	27.12
3	0	0.5	0.0601	75%	3674	1224	1000	32.84	32.35	27.7
3	0	0.5	0.0701	75%	3674	1224	1000	6.05	32.35	31.86
3	0	0.5	0.0801	75%	3674	1224	1000	6.05	7.35	27.04
3	0	0.5	0.0901	75%	3674	1224	1000	33.01	25.57	26.88
3	0	0.5	0.1001	75%	3674	1224	1000	32.84	32.84	31.29
4	0	0.5	0.0001	75%	3674	1224	1000	27.7	21.08	20.1
4	0	0.5	0.0101	75%	3674	1224	1000	39.22	8.01	40.85
4	0	0.5	0.0201	75%	3674	1224	1000	41.91	37.5	39.87
4	0	0.5	0.0301	75%	3674	1224	1000	41.99	38.24	41.91
4	0	0.5	0.0401	75%	3674	1224	1000	42.08	37.83	41.75
4	0	0.5	0.0501	75%	3674	1224	1000	41.83	39.95	41.67
4	0	0.5	0.0601	75%	3674	1224	1000	7.84	38.73	41.58
4	0	0.5	0.0701	75%	3674	1224	1000	12.17	37.75	41.75
4	0	0.5	0.0801	75%	3674	1224	1000	7.92	41.67	42.08
4	0	0.5	0.0901	75%	3674	1224	1000	12.17	37.66	41.99
4	0	0.5	0.1001	75%	3674	1224	1000	41.83	41.67	42.16
5	0	0.5	0.0001	75%	3674	1224	1000	16.18	21.08	18.87
5	0	0.5	0.0101	75%	3674	1224	1000	37.09	37.17	35.87
5	0	0.5	0.0201	75%	3674	1224	1000	35.87	31.13	36.36
5	0	0.5	0.0301	75%	3674	1224	1000	34.97	35.46	36.52
5	0	0.5	0.0401	75%	3674	1224	1000	35.05	36.27	36.19
5	0	0.5	0.0501	75%	3674	1224	1000	35.13	35.21	35.38
5	0	0.5	0.0601	75%	3674	1224	1000	35.62	35.29	35.62

5	0	0.5	0.0701	75%	3674	1224	1000	35.54	34.8	35.38
5	0	0.5	0.0801	75%	3674	1224	1000	35.38	35.21	35.7
5	0	0.5	0.0901	75%	3674	1224	1000	35.87	34.97	35.38
5	0	0.5	0.1001	75%	3674	1224	1000	35.46	35.29	35.46
6	0	0.5	0.0001	75%	3674	1224	1000	17.08	16.67	14.46
6	0	0.5	0.0101	75%	3674	1224	1000	34.23	36.85	36.44
6	0	0.5	0.0201	75%	3674	1224	1000	36.44	36.6	36.68
6	0	0.5	0.0301	75%	3674	1224	1000	36.36	36.36	36.68
6	0	0.5	0.0401	75%	3674	1224	1000	35.38	34.56	36.68
6	0	0.5	0.0501	75%	3674	1224	1000	34.8	34.72	16.67
6	0	0.5	0.0601	75%	3674	1224	1000	8.17	6.78	8.17
6	0	0.5	0.0701	75%	3674	1224	1000	8.09	6.78	18.87
6	0	0.5	0.0801	75%	3674	1224	1000	6.62	6.62	8.09
6	0	0.5	0.0901	75%	3674	1224	1000	6.78	6.54	7.19
6	0	0.5	0.1001	75%	3674	1224	1000	8.17	6.54	6.62
7	0	0.5	0.0001	75%	3674	1224	1000	29.98	24.02	19.93
7	0	0.5	0.0101	75%	3674	1224	1000	42.73	42.57	42.08
7	0	0.5	0.0201	75%	3674	1224	1000	42.73	41.83	42.16
7	0	0.5	0.0301	75%	3674	1224	1000	42.08	41.99	41.99
7	0	0.5	0.0401	75%	3674	1224	1000	41.83	42.16	41.99
7	0	0.5	0.0501	75%	3674	1224	1000	41.83	42.16	41.99
7	0	0.5	0.0601	75%	3674	1224	1000	41.83	42.24	42.08
7	0	0.5	0.0701	75%	3674	1224	1000	41.99	42.48	42.16
7	0	0.5	0.0801	75%	3674	1224	1000	42.24	42.32	42.32
7	0	0.5	0.0901	75%	3674	1224	1000	42.32	42.24	38.64
7	0	0.5	0.1001	75%	3674	1224	1000	42.08	5.56	38.48
8	0	0.5	0.0001	75%	3674	1224	1000	9.15	18.22	25.98
8	0	0.5	0.0101	75%	3674	1224	1000	39.13	42.08	39.87
8	0	0.5	0.0201	75%	3674	1224	1000	41.42	41.58	42.08
8	0	0.5	0.0301	75%	3674	1224	1000	42.24	41.18	41.67
8	0	0.5	0.0401	75%	3674	1224	1000	41.75	41.26	41.58
8	0	0.5	0.0501	75%	3674	1224	1000	41.42	40.85	18.14
8	0	0.5	0.0601	75%	3674	1224	1000	41.34	41.18	18.3
8	0	0.5	0.0701	75%	3674	1224	1000	41.5	18.06	18.14
8	0	0.5	0.0801	75%	3674	1224	1000	18.06	38.89	18.14
8	0	0.5	0.0901	75%	3674	1224	1000	18.06	41.26	18.14
8	0	0.5	0.1001	75%	3674	1224	1000	41.34	18.06	18.14
9	0	0.5	0.0001	75%	3674	1224	1000	33.82	21.73	17.97
9	0	0.5	0.0101	75%	3674	1224	1000	45.42	44.69	42.73
9	0	0.5	0.0201	75%	3674	1224	1000	42.81	41.01	18.22
9	0	0.5	0.0301	75%	3674	1224	1000	36.11	11.11	9.48
9	0	0.5	0.0401	75%	3674	1224	1000	18.06	11.11	36.11
9	0	0.5	0.0501	75%	3674	1224	1000	17.57	7.35	36.11
9	0	0.5	0.0601	75%	3674	1224	1000	17.65	35.87	36.19
9	0	0.5	0.0701	75%	3674	1224	1000	16.67	11.6	36.6
9	0	0.5	0.0801	75%	3674	1224	1000	16.67	10.21	36.27
9	0	0.5	0.0901	75%	3674	1224	1000	16.99	10.21	36.27
9	0	0.5	0.1001	75%	3674	1224	1000	36.03	10.21	36.36
10	0	0.5	0.0001	75%	3674	1224	1000	31.62	17.32	18.3
10	0	0.5	0.0101	75%	3674	1224	1000	23.04	37.66	28.43
10	0	0.5	0.0201	75%	3674	1224	1000	28.1	33.01	27.45
10	0	0.5	0.0301	75%	3674	1224	1000	19.85	27.7	28.19
10	0	0.5	0.0401	75%	3674	1224	1000	27.45	29.41	28.51
10	0	0.5	0.0501	75%	3674	1224	1000	5.47	26.8	27.53
10	0	0.5	0.0601	75%	3674	1224	1000	30.8	29.9	27.45

10	0	0.5	0.0701	75%	3674	1224	1000	4.41	26.8	26.72
10	0	0.5	0.0801	75%	3674	1224	1000	30.72	27.61	28.19
10	0	0.5	0.0901	75%	3674	1224	1000	10.05	26.96	26.8
10	0	0.5	0.1001	75%	3674	1224	1000	7.03	24.18	26.88
11	0	0.5	0.0001	75%	3674	1224	1000	15.69	16.99	18.46
11	0	0.5	0.0101	75%	3674	1224	1000	36.76	36.19	36.19
11	0	0.5	0.0201	75%	3674	1224	1000	35.21	35.13	37.99
11	0	0.5	0.0301	75%	3674	1224	1000	34.23	15.28	37.42
11	0	0.5	0.0401	75%	3674	1224	1000	34.97	34.64	34.48
11	0	0.5	0.0501	75%	3674	1224	1000	19.36	16.83	27.12
11	0	0.5	0.0601	75%	3674	1224	1000	15.6	18.63	27.37
11	0	0.5	0.0701	75%	3674	1224	1000	15.28	17.89	27.45
11	0	0.5	0.0801	75%	3674	1224	1000	15.52	19.36	27.12
11	0	0.5	0.0901	75%	3674	1224	1000	19.36	35.38	27.29
11	0	0.5	0.1001	75%	3674	1224	1000	15.69	17.97	26.72
12	0	0.5	0.0001	75%	3674	1224	1000	16.5	31.86	17.89
12	0	0.5	0.0101	75%	3674	1224	1000	38.4	39.87	27.78
12	0	0.5	0.0201	75%	3674	1224	1000	36.76	40.2	36.68
12	0	0.5	0.0301	75%	3674	1224	1000	36.44	36.68	36.85
12	0	0.5	0.0401	75%	3674	1224	1000	36.6	36.44	36.68
12	0	0.5	0.0501	75%	3674	1224	1000	31.29	36.03	36.85
12	0	0.5	0.0601	75%	3674	1224	1000	31.86	31.45	31.54
12	0	0.5	0.0701	75%	3674	1224	1000	31.62	32.43	30.88
12	0	0.5	0.0801	75%	3674	1224	1000	31.45	32.6	31.21
12	0	0.5	0.0901	75%	3674	1224	1000	37.75	33.09	32.11
12	0	0.5	0.1001	75%	3674	1224	1000	31.62	35.87	31.29

Lampiran 5 Tabel pengujian pengaruh jumlah data latih terhadap hasil akurasi dataset *red wine*, minSupp=0, minConf=0.5, learning rate=0.0201, epoch1000

Uji	Min Supp.	Min Conf.	Learn. Rate	Data Latih	Jum Latih	Jum Uji	Max Epoh	Centroid 1	Centroid 2	Centroid 3
1	0	0.5	0.0201	10%	160	1439	1000	47.95	48.85	45.1
1	0	0.5	0.0201	20%	321	1278	1000	54.46	55.4	52.9
1	0	0.5	0.0201	30%	479	1120	1000	33.48	40.8	44.2
1	0	0.5	0.0201	40%	639	960	1000	46.46	51.15	47.19
1	0	0.5	0.0201	50%	801	798	1000	52.13	53.38	53.76
1	0	0.5	0.0201	60%	960	639	1000	45.7	46.79	47.1
1	0	0.5	0.0201	70%	1120	479	1000	45.93	45.09	47.18
1	0	0.5	0.0201	80%	1278	321	1000	51.71	55.14	51.71
1	0	0.5	0.0201	90%	1439	160	1000	31.88	45	41.88
2	0	0.5	0.0201	10%	160	1439	1000	50.1	48.92	45.59
2	0	0.5	0.0201	20%	321	1278	1000	55.95	55.95	54.85
2	0	0.5	0.0201	30%	479	1120	1000	53.84	49.91	49.2
2	0	0.5	0.0201	40%	639	960	1000	49.48	46.35	39.17
2	0	0.5	0.0201	50%	801	798	1000	46.62	44.49	40.23
2	0	0.5	0.0201	60%	960	639	1000	56.96	57.12	57.12
2	0	0.5	0.0201	70%	1120	479	1000	48.02	50.1	49.27
2	0	0.5	0.0201	80%	1278	321	1000	43.3	42.68	44.86
2	0	0.5	0.0201	90%	1439	160	1000	42.5	46.25	41.88
3	0	0.5	0.0201	10%	160	1439	1000	50.38	47.95	49.13
3	0	0.5	0.0201	20%	321	1278	1000	52.82	54.38	56.03
3	0	0.5	0.0201	30%	479	1120	1000	53.21	49.91	49.2
3	0	0.5	0.0201	40%	639	960	1000	56.25	53.75	51.77
3	0	0.5	0.0201	50%	801	798	1000	49.62	49.62	46.74
3	0	0.5	0.0201	60%	960	639	1000	46.01	46.01	47.1
3	0	0.5	0.0201	70%	1120	479	1000	51.77	53.44	53.24
3	0	0.5	0.0201	80%	1278	321	1000	38.94	44.24	39.56
3	0	0.5	0.0201	90%	1439	160	1000	42.5	35	42.5
4	0	0.5	0.0201	10%	160	1439	1000	54	53.58	55.04
4	0	0.5	0.0201	20%	321	1278	1000	48.2	42.8	47.18
4	0	0.5	0.0201	30%	479	1120	1000	39.91	42.5	55.09
4	0	0.5	0.0201	40%	639	960	1000	56.67	45.83	47.81
4	0	0.5	0.0201	50%	801	798	1000	43.61	47.49	44.36
4	0	0.5	0.0201	60%	960	639	1000	50.08	49.61	49.45
4	0	0.5	0.0201	70%	1120	479	1000	54.91	55.32	55.11
4	0	0.5	0.0201	80%	1278	321	1000	36.45	28.35	33.33
4	0	0.5	0.0201	90%	1439	160	1000	53.75	50.63	45
5	0	0.5	0.0201	10%	160	1439	1000	56.29	55.66	54.69
5	0	0.5	0.0201	20%	321	1278	1000	54.62	53.52	52.74
5	0	0.5	0.0201	30%	479	1120	1000	44.91	45.8	45
5	0	0.5	0.0201	40%	639	960	1000	22.92	54.58	56.04
5	0	0.5	0.0201	50%	801	798	1000	53.38	37.59	49.25
5	0	0.5	0.0201	60%	960	639	1000	48.36	42.72	39.44
5	0	0.5	0.0201	70%	1120	479	1000	44.89	42.17	44.89
5	0	0.5	0.0201	80%	1278	321	1000	48.91	51.09	48.29
5	0	0.5	0.0201	90%	1439	160	1000	48.13	46.88	51.88
6	0	0.5	0.0201	10%	160	1439	1000	52.81	43.57	47.6
6	0	0.5	0.0201	20%	321	1278	1000	50.86	47.34	51.33
6	0	0.5	0.0201	30%	479	1120	1000	49.29	49.2	49.46
6	0	0.5	0.0201	40%	639	960	1000	55.21	55.42	53.13
6	0	0.5	0.0201	50%	801	798	1000	39.6	41.35	43.61
6	0	0.5	0.0201	60%	960	639	1000	43.51	43.82	34.43

6	0	0.5	0.0201	70%	1120	479	1000	41.96	53.24	55.74
6	0	0.5	0.0201	80%	1278	321	1000	43.93	43.61	44.24
6	0	0.5	0.0201	90%	1439	160	1000	39.38	42.5	42.5
7	0	0.5	0.0201	10%	160	1439	1000	54.48	54.41	55.11
7	0	0.5	0.0201	20%	321	1278	1000	54.62	53.76	44.84
7	0	0.5	0.0201	30%	479	1120	1000	49.64	53.39	53.66
7	0	0.5	0.0201	40%	639	960	1000	48.44	51.25	52.92
7	0	0.5	0.0201	50%	801	798	1000	46.87	47.49	56.52
7	0	0.5	0.0201	60%	960	639	1000	39.28	51.8	37.09
7	0	0.5	0.0201	70%	1120	479	1000	46.56	43.84	42.59
7	0	0.5	0.0201	80%	1278	321	1000	52.34	52.34	57.01
7	0	0.5	0.0201	90%	1439	160	1000	37.5	50	40
8	0	0.5	0.0201	10%	160	1439	1000	55.73	45.17	56.91
8	0	0.5	0.0201	20%	321	1278	1000	54.23	55.48	56.49
8	0	0.5	0.0201	30%	479	1120	1000	54.11	52.95	54.91
8	0	0.5	0.0201	40%	639	960	1000	56.88	51.67	47.5
8	0	0.5	0.0201	50%	801	798	1000	54.26	54.64	46.24
8	0	0.5	0.0201	60%	960	639	1000	39.75	42.72	46.48
8	0	0.5	0.0201	70%	1120	479	1000	43.63	44.05	41.54
8	0	0.5	0.0201	80%	1278	321	1000	42.06	37.38	41.74
8	0	0.5	0.0201	90%	1439	160	1000	43.13	43.13	55
9	0	0.5	0.0201	10%	160	1439	1000	55.87	53.93	55.94
9	0	0.5	0.0201	20%	321	1278	1000	51.56	36.38	36.46
9	0	0.5	0.0201	30%	479	1120	1000	50.27	49.29	46.16
9	0	0.5	0.0201	40%	639	960	1000	42.08	49.79	45.83
9	0	0.5	0.0201	50%	801	798	1000	47.87	52.13	48.62
9	0	0.5	0.0201	60%	960	639	1000	52.74	46.17	44.6
9	0	0.5	0.0201	70%	1120	479	1000	46.14	53.44	42.38
9	0	0.5	0.0201	80%	1278	321	1000	52.02	52.65	52.34
9	0	0.5	0.0201	90%	1439	160	1000	56.25	47.5	48.75
10	0	0.5	0.0201	10%	160	1439	1000	40.79	46.84	41.21
10	0	0.5	0.0201	20%	321	1278	1000	53.52	53.68	54.46
10	0	0.5	0.0201	30%	479	1120	1000	44.29	58.13	43.66
10	0	0.5	0.0201	40%	639	960	1000	46.15	47.81	54.38
10	0	0.5	0.0201	50%	801	798	1000	49.37	38.72	44.11
10	0	0.5	0.0201	60%	960	639	1000	47.73	47.1	48.98
10	0	0.5	0.0201	70%	1120	479	1000	47.39	46.97	44.05
10	0	0.5	0.0201	80%	1278	321	1000	39.25	42.37	44.24
10	0	0.5	0.0201	90%	1439	160	1000	45	38.75	41.88
11	0	0.5	0.0201	10%	160	1439	1000	50.66	48.02	49.76
11	0	0.5	0.0201	20%	321	1278	1000	49.53	48.75	52.03
11	0	0.5	0.0201	30%	479	1120	1000	44.91	48.48	46.43
11	0	0.5	0.0201	40%	639	960	1000	49.79	45.83	50.31
11	0	0.5	0.0201	50%	801	798	1000	38.47	44.74	43.48
11	0	0.5	0.0201	60%	960	639	1000	46.32	46.64	46.48
11	0	0.5	0.0201	70%	1120	479	1000	54.91	53.44	53.44
11	0	0.5	0.0201	80%	1278	321	1000	26.17	34.27	56.7
11	0	0.5	0.0201	90%	1439	160	1000	47.5	43.13	43.13
12	0	0.5	0.0201	10%	160	1439	1000	48.78	52.05	53.58
12	0	0.5	0.0201	20%	321	1278	1000	52.5	52.66	39.83
12	0	0.5	0.0201	30%	479	1120	1000	54.82	54.82	54.11
12	0	0.5	0.0201	40%	639	960	1000	56.35	56.35	58.23
12	0	0.5	0.0201	50%	801	798	1000	46.87	51.75	52.76
12	0	0.5	0.0201	60%	960	639	1000	54.62	46.64	46.95
12	0	0.5	0.0201	70%	1120	479	1000	37.37	46.35	36.12

12	0	0.5	0.0201	80%	1278	321	1000	47.04	40.81	49.84
12	0	0.5	0.0201	90%	1439	160	1000	39.38	43.75	39.38



Lampiran 6 Tabel pengujian pengaruh jumlah data latih terhadap hasil akurasi dataset *white wine*, $\text{minSupp}=0$, $\text{minConf}=0.5$, $\text{learning rate}=0.0201$, epoh 1000

Uji	Min Supp.	Min Conf.	Learn. Rate	Data Latih	Jum Latih	Jum Uji	Max Epoh	Centroid 1	Centroid 2	Centroid 3
1	0	0.5	0.0201	10%	491	4407	1000	14.95	30.66	33.4
1	0	0.5	0.0201	20%	980	3918	1000	36.68	39.71	43.11
1	0	0.5	0.0201	30%	1470	3428	1000	42.74	46.35	46.18
1	0	0.5	0.0201	40%	1959	2939	1000	10.48	14.36	7.15
1	0	0.5	0.0201	50%	2451	2447	1000	3.11	38.13	35.51
1	0	0.5	0.0201	60%	2939	1959	1000	35.48	43.44	41.76
1	0	0.5	0.0201	70%	3430	1468	1000	26.36	32.9	13.96
1	0	0.5	0.0201	80%	3918	980	1000	37.86	40.1	40.51
1	0	0.5	0.0201	90%	4409	489	1000	7.98	30.27	33.13
2	0	0.5	0.0201	10%	491	4407	1000	43.7	37.87	50.87
2	0	0.5	0.0201	20%	980	3918	1000	9.16	15.77	15.7
2	0	0.5	0.0201	30%	1470	3428	1000	5.16	12.6	13.45
2	0	0.5	0.0201	40%	1959	2939	1000	8.23	9.73	19.97
2	0	0.5	0.0201	50%	2451	2447	1000	11.85	34.12	11.61
2	0	0.5	0.0201	60%	2939	1959	1000	38.44	35.48	35.68
2	0	0.5	0.0201	70%	3430	1468	1000	26.43	28.54	8.65
2	0	0.5	0.0201	80%	3918	980	1000	21.02	40	39.8
2	0	0.5	0.0201	90%	4409	489	1000	35.17	35.17	7.57
3	0	0.5	0.0201	10%	491	4407	1000	45.16	47.52	19.45
3	0	0.5	0.0201	20%	980	3918	1000	12.15	40.22	24.12
3	0	0.5	0.0201	30%	1470	3428	1000	44.17	42.88	42.79
3	0	0.5	0.0201	40%	1959	2939	1000	32.6	41.88	36.65
3	0	0.5	0.0201	50%	2451	2447	1000	4.5	7.03	5.52
3	0	0.5	0.0201	60%	2939	1959	1000	17.87	7.5	20.98
3	0	0.5	0.0201	70%	3430	1468	1000	5.65	35.22	29.77
3	0	0.5	0.0201	80%	3918	980	1000	39.08	38.27	37.55
3	0	0.5	0.0201	90%	4409	489	1000	9.61	5.52	5.32
4	0	0.5	0.0201	10%	491	4407	1000	25.91	38.57	41.43
4	0	0.5	0.0201	20%	980	3918	1000	27.49	5.87	10.85
4	0	0.5	0.0201	30%	1470	3428	1000	40.9	42.47	42.59
4	0	0.5	0.0201	40%	1959	2939	1000	42.6	42.43	42.16
4	0	0.5	0.0201	50%	2451	2447	1000	43.03	40.25	42.62
4	0	0.5	0.0201	60%	2939	1959	1000	41.55	34.35	36.8
4	0	0.5	0.0201	70%	3430	1468	1000	5.31	5.72	4.43
4	0	0.5	0.0201	80%	3918	980	1000	6.94	7.96	5.1
4	0	0.5	0.0201	90%	4409	489	1000	42.74	5.32	41.1
5	0	0.5	0.0201	10%	491	4407	1000	46.13	43.73	15.11
5	0	0.5	0.0201	20%	980	3918	1000	33.51	8.12	34.89
5	0	0.5	0.0201	30%	1470	3428	1000	39.96	40.96	35.97
5	0	0.5	0.0201	40%	1959	2939	1000	24.26	43.48	12.49
5	0	0.5	0.0201	50%	2451	2447	1000	41.85	39.52	9.85
5	0	0.5	0.0201	60%	2939	1959	1000	37.67	29.1	27.05
5	0	0.5	0.0201	70%	3430	1468	1000	39.17	6.88	38.96
5	0	0.5	0.0201	80%	3918	980	1000	27.96	41.02	41.33
5	0	0.5	0.0201	90%	4409	489	1000	34.56	5.52	34.56
6	0	0.5	0.0201	10%	491	4407	1000	46.56	45.86	25.85
6	0	0.5	0.0201	20%	980	3918	1000	20.52	38.03	11.1
6	0	0.5	0.0201	30%	1470	3428	1000	41.72	41.8	10.33
6	0	0.5	0.0201	40%	1959	2939	1000	37.7	40.59	40.73
6	0	0.5	0.0201	50%	2451	2447	1000	27.38	21.58	25.21
6	0	0.5	0.0201	60%	2939	1959	1000	39.87	33.84	31.19

6	0	0.5	0.0201	70%	3430	1468	1000	7.22	5.25	6.54
6	0	0.5	0.0201	80%	3918	980	1000	34.8	6.84	36.02
6	0	0.5	0.0201	90%	4409	489	1000	36.4	39.47	40.08
7	0	0.5	0.0201	10%	491	4407	1000	44.36	50.85	49.97
7	0	0.5	0.0201	20%	980	3918	1000	31.9	44.46	43.03
7	0	0.5	0.0201	30%	1470	3428	1000	32.64	44.46	40.55
7	0	0.5	0.0201	40%	1959	2939	1000	25.11	31.81	7.49
7	0	0.5	0.0201	50%	2451	2447	1000	40.78	38.99	9.85
7	0	0.5	0.0201	60%	2939	1959	1000	22.41	12.35	14.24
7	0	0.5	0.0201	70%	3430	1468	1000	39.24	39.31	39.24
7	0	0.5	0.0201	80%	3918	980	1000	41.02	38.67	41.33
7	0	0.5	0.0201	90%	4409	489	1000	37.01	40.08	39.06
8	0	0.5	0.0201	10%	491	4407	1000	50.74	49.81	50.47
8	0	0.5	0.0201	20%	980	3918	1000	15.75	14.68	16.82
8	0	0.5	0.0201	30%	1470	3428	1000	35.62	6.07	10.62
8	0	0.5	0.0201	40%	1959	2939	1000	35.05	36.13	39.57
8	0	0.5	0.0201	50%	2451	2447	1000	33.47	19.74	17.04
8	0	0.5	0.0201	60%	2939	1959	1000	38.08	6.53	37.42
8	0	0.5	0.0201	70%	3430	1468	1000	5.93	4.7	5.11
8	0	0.5	0.0201	80%	3918	980	1000	18.16	5.61	6.53
8	0	0.5	0.0201	90%	4409	489	1000	37.63	37.63	39.06
9	0	0.5	0.0201	10%	491	4407	1000	40.41	36.01	46.22
9	0	0.5	0.0201	20%	980	3918	1000	7.2	12.86	11.54
9	0	0.5	0.0201	30%	1470	3428	1000	16.74	18.47	37.28
9	0	0.5	0.0201	40%	1959	2939	1000	41.41	40.12	41.99
9	0	0.5	0.0201	50%	2451	2447	1000	26.85	7.93	27.09
9	0	0.5	0.0201	60%	2939	1959	1000	36.86	29.15	39.46
9	0	0.5	0.0201	70%	3430	1468	1000	3.54	3.27	35.69
9	0	0.5	0.0201	80%	3918	980	1000	39.8	40.1	8.06
9	0	0.5	0.0201	90%	4409	489	1000	36.81	37.01	5.32
10	0	0.5	0.0201	10%	491	4407	1000	43.48	15.63	47.67
10	0	0.5	0.0201	20%	980	3918	1000	40.33	38.62	8.55
10	0	0.5	0.0201	30%	1470	3428	1000	38.62	10.24	40.61
10	0	0.5	0.0201	40%	1959	2939	1000	43.38	43.82	43.96
10	0	0.5	0.0201	50%	2451	2447	1000	40.01	40.74	36.9
10	0	0.5	0.0201	60%	2939	1959	1000	34.66	30.07	32.06
10	0	0.5	0.0201	70%	3430	1468	1000	28.2	36.24	41.69
10	0	0.5	0.0201	80%	3918	980	1000	36.12	38.67	36.73
10	0	0.5	0.0201	90%	4409	489	1000	13.5	15.75	15.13
11	0	0.5	0.0201	10%	491	4407	1000	28	45.02	41.64
11	0	0.5	0.0201	20%	980	3918	1000	29.35	6.99	14.57
11	0	0.5	0.0201	30%	1470	3428	1000	26.28	44.05	43.99
11	0	0.5	0.0201	40%	1959	2939	1000	10.38	16.33	19.36
11	0	0.5	0.0201	50%	2451	2447	1000	38.86	35.02	38.66
11	0	0.5	0.0201	60%	2939	1959	1000	42.42	41.19	42.73
11	0	0.5	0.0201	70%	3430	1468	1000	35.83	31.81	30.25
11	0	0.5	0.0201	80%	3918	980	1000	34.8	33.67	32.24
11	0	0.5	0.0201	90%	4409	489	1000	37.22	39.67	38.24
12	0	0.5	0.0201	10%	491	4407	1000	24.76	40.89	40
12	0	0.5	0.0201	20%	980	3918	1000	32.67	33.41	37.26
12	0	0.5	0.0201	30%	1470	3428	1000	12.19	11.17	10.5
12	0	0.5	0.0201	40%	1959	2939	1000	25.42	42.77	37.67
12	0	0.5	0.0201	50%	2451	2447	1000	40.62	41.68	42.17
12	0	0.5	0.0201	60%	2939	1959	1000	31.7	13.58	32.72
12	0	0.5	0.0201	70%	3430	1468	1000	13.08	5.93	5.25

12	0	0.5	0.0201	80%	3918	980	1000	7.45	6.12	8.27
12	0	0.5	0.0201	90%	4409	489	1000	36.81	25.15	36.4



Lampiran 7 Tabel pengujian pengaruh maksimum epoh terhadap hasil akurasi dataset *red wine*, minSupp=0, minConf=0.5, learning rate 0.0201 , jumlah data latih 75%.

Uji	Min Supp.	Min Conf.	Learn. Rate	Data Latih	Jum Latih	Jum Uji	Max Epoh	Centroid 1	Centroid 2	Centroid 3
1	0	0.5	0.0201	75%	1201	398	100	31.66	34.92	27.39
1	0	0.5	0.0201	75%	1201	398	500	47.74	52.51	44.22
1	0	0.5	0.0201	75%	1201	398	1000	52.01	50	51.76
1	0	0.5	0.0201	75%	1201	398	1600	51.26	51.76	52.76
1	0	0.5	0.0201	75%	1201	398	2300	51.26	53.27	52.51
1	0	0.5	0.0201	75%	1201	398	3100	51.26	53.27	52.51
1	0	0.5	0.0201	75%	1201	398	4000	51.26	53.27	52.51
1	0	0.5	0.0201	75%	1201	398	5000	51.26	53.27	52.51
2	0	0.5	0.0201	75%	1201	398	100	24.12	21.61	21.11
2	0	0.5	0.0201	75%	1201	398	500	54.27	50.25	45.73
2	0	0.5	0.0201	75%	1201	398	1000	54.02	54.02	47.24
2	0	0.5	0.0201	75%	1201	398	1600	55.78	56.28	50.75
2	0	0.5	0.0201	75%	1201	398	2300	57.04	56.28	54.27
2	0	0.5	0.0201	75%	1201	398	3100	57.04	56.28	54.27
2	0	0.5	0.0201	75%	1201	398	4000	57.04	56.28	54.27
2	0	0.5	0.0201	75%	1201	398	5000	57.04	56.28	54.27
3	0	0.5	0.0201	75%	1201	398	100	21.11	15.33	18.59
3	0	0.5	0.0201	75%	1201	398	500	37.69	44.47	41.21
3	0	0.5	0.0201	75%	1201	398	1000	39.2	44.22	44.97
3	0	0.5	0.0201	75%	1201	398	1600	41.21	48.99	46.73
3	0	0.5	0.0201	75%	1201	398	2300	41.21	46.98	47.99
3	0	0.5	0.0201	75%	1201	398	3100	40.7	47.24	48.74
3	0	0.5	0.0201	75%	1201	398	4000	40.7	47.24	48.24
3	0	0.5	0.0201	75%	1201	398	5000	40.7	47.24	47.74
4	0	0.5	0.0201	75%	1201	398	100	26.13	23.37	27.89
4	0	0.5	0.0201	75%	1201	398	500	42.21	45.73	41.96
4	0	0.5	0.0201	75%	1201	398	1000	47.99	45.23	47.74
4	0	0.5	0.0201	75%	1201	398	1600	51.01	54.27	52.51
4	0	0.5	0.0201	75%	1201	398	2300	53.77	54.27	53.52
4	0	0.5	0.0201	75%	1201	398	3100	54.27	54.27	53.52
4	0	0.5	0.0201	75%	1201	398	4000	54.27	54.27	53.52
4	0	0.5	0.0201	75%	1201	398	5000	54.27	54.27	53.52
5	0	0.5	0.0201	75%	1201	398	100	42.71	36.18	26.63
5	0	0.5	0.0201	75%	1201	398	500	33.67	36.18	38.44
5	0	0.5	0.0201	75%	1201	398	1000	42.96	42.71	41.96
5	0	0.5	0.0201	75%	1201	398	1600	39.7	46.73	44.97
5	0	0.5	0.0201	75%	1201	398	2300	40.95	47.99	45.48
5	0	0.5	0.0201	75%	1201	398	3100	38.69	48.49	47.49
5	0	0.5	0.0201	75%	1201	398	4000	38.19	49.75	48.24
5	0	0.5	0.0201	75%	1201	398	5000	34.42	46.23	48.99
6	0	0.5	0.0201	75%	1201	398	100	26.13	23.37	27.89
6	0	0.5	0.0201	75%	1201	398	500	42.21	45.73	41.96
6	0	0.5	0.0201	75%	1201	398	1000	47.99	45.23	47.74
6	0	0.5	0.0201	75%	1201	398	1600	51.01	54.27	52.51
6	0	0.5	0.0201	75%	1201	398	2300	53.77	54.27	53.52
6	0	0.5	0.0201	75%	1201	398	3100	54.27	54.27	53.52
6	0	0.5	0.0201	75%	1201	398	4000	54.27	54.27	53.52
6	0	0.5	0.0201	75%	1201	398	5000	54.27	54.27	53.52
7	0	0.5	0.0201	75%	1201	398	100	17.34	32.41	29.15
7	0	0.5	0.0201	75%	1201	398	500	57.54	56.78	49.5
7	0	0.5	0.0201	75%	1201	398	1000	55.78	57.04	53.02

7	0	0.5	0.0201	75%	1201	398	1600	57.79	54.52	58.29
7	0	0.5	0.0201	75%	1201	398	2300	57.79	54.52	58.29
7	0	0.5	0.0201	75%	1201	398	3100	57.79	54.52	58.29
7	0	0.5	0.0201	75%	1201	398	4000	57.79	54.52	58.29
7	0	0.5	0.0201	75%	1201	398	5000	57.79	54.52	58.29
8	0	0.5	0.0201	75%	1201	398	100	33.42	25.13	22.61
8	0	0.5	0.0201	75%	1201	398	500	44.72	45.73	45.23
8	0	0.5	0.0201	75%	1201	398	1000	50.75	50.75	47.24
8	0	0.5	0.0201	75%	1201	398	1600	49.5	52.51	51.51
8	0	0.5	0.0201	75%	1201	398	2300	50.5	52.51	52.26
8	0	0.5	0.0201	75%	1201	398	3100	50.5	52.51	51.51
8	0	0.5	0.0201	75%	1201	398	4000	50.5	52.51	51.51
8	0	0.5	0.0201	75%	1201	398	5000	50.5	52.51	51.51
9	0	0.5	0.0201	75%	1201	398	100	42.71	23.37	20.1
9	0	0.5	0.0201	75%	1201	398	500	38.69	41.21	40.2
9	0	0.5	0.0201	75%	1201	398	1000	46.48	45.23	46.48
9	0	0.5	0.0201	75%	1201	398	1600	49.25	43.22	48.74
9	0	0.5	0.0201	75%	1201	398	2300	48.49	42.96	48.24
9	0	0.5	0.0201	75%	1201	398	3100	49.75	28.64	47.99
9	0	0.5	0.0201	75%	1201	398	4000	49.75	27.64	48.24
9	0	0.5	0.0201	75%	1201	398	5000	49.5	28.39	37.44
10	0	0.5	0.0201	75%	1201	398	100	35.93	20.85	38.19
10	0	0.5	0.0201	75%	1201	398	500	47.74	47.99	37.69
10	0	0.5	0.0201	75%	1201	398	1000	52.01	51.26	54.77
10	0	0.5	0.0201	75%	1201	398	1600	56.03	50.25	55.78
10	0	0.5	0.0201	75%	1201	398	2300	56.03	52.51	56.53
10	0	0.5	0.0201	75%	1201	398	3100	56.03	52.51	56.53
10	0	0.5	0.0201	75%	1201	398	4000	56.03	52.51	56.53
10	0	0.5	0.0201	75%	1201	398	5000	56.03	52.51	56.53
11	0	0.5	0.0201	75%	1201	398	100	42.46	30.9	33.42
11	0	0.5	0.0201	75%	1201	398	500	36.93	47.24	38.19
11	0	0.5	0.0201	75%	1201	398	1000	42.96	48.99	42.21
11	0	0.5	0.0201	75%	1201	398	1600	46.48	52.51	43.47
11	0	0.5	0.0201	75%	1201	398	2300	46.48	51.51	41.21
11	0	0.5	0.0201	75%	1201	398	3100	47.24	51.51	41.96
11	0	0.5	0.0201	75%	1201	398	4000	47.49	51.51	42.21
11	0	0.5	0.0201	75%	1201	398	5000	8.29	51.51	42.21
12	0	0.5	0.0201	75%	1201	398	100	45.73	47.24	50
12	0	0.5	0.0201	75%	1201	398	500	48.74	46.23	51.76
12	0	0.5	0.0201	75%	1201	398	1000	51.26	48.74	53.77
12	0	0.5	0.0201	75%	1201	398	1600	50.75	49.75	52.51
12	0	0.5	0.0201	75%	1201	398	2300	49.25	50.75	50.5
12	0	0.5	0.0201	75%	1201	398	3100	49.75	50.75	49.5
12	0	0.5	0.0201	75%	1201	398	4000	49.75	50.75	49.5
12	0	0.5	0.0201	75%	1201	398	5000	49.75	50.75	49.5
13	0	0.5	0.0201	75%	1201	398	100	52.26	49.25	48.49
13	0	0.5	0.0201	75%	1201	398	500	49.5	49.75	41.21
13	0	0.5	0.0201	75%	1201	398	1000	47.49	52.76	47.24
13	0	0.5	0.0201	75%	1201	398	1600	48.74	53.77	47.49
13	0	0.5	0.0201	75%	1201	398	2300	47.49	52.76	47.24
13	0	0.5	0.0201	75%	1201	398	3100	47.74	52.51	48.74
13	0	0.5	0.0201	75%	1201	398	4000	48.49	52.51	48.49
13	0	0.5	0.0201	75%	1201	398	5000	48.24	52.51	48.24
14	0	0.5	0.0201	75%	1201	398	100	26.13	28.14	26.63
14	0	0.5	0.0201	75%	1201	398	500	33.92	44.22	33.42

14	0	0.5	0.0201	75%	1201	398	1000	44.22	47.74	43.22
14	0	0.5	0.0201	75%	1201	398	1600	47.24	46.73	46.48
14	0	0.5	0.0201	75%	1201	398	2300	47.74	44.47	47.99
14	0	0.5	0.0201	75%	1201	398	3100	49.25	45.23	47.49
14	0	0.5	0.0201	75%	1201	398	4000	48.49	44.97	46.48
14	0	0.5	0.0201	75%	1201	398	5000	48.24	44.97	46.48



Lampiran 8 Tabel pengujian pengaruh maksimum epoh terhadap hasil akurasi *dataset white wine*, $\text{minSupp}=0$, $\text{minConf}=0.5$, $\text{learning rate } 0.0201$, jumlah data latih 75%.

Uji	Min Supp.	Min Conf.	Learn. Rate	Data Latih	Jum Latih	Jum Uji	Max Epoh	Centroid 1	Centroid 2	Centroid 3
1	0	0.5	0.0201	75%	3674	1224	100	27.7	27.7	27.7
1	0	0.5	0.0201	75%	3674	1224	500	29.25	28.59	39.46
1	0	0.5	0.0201	75%	3674	1224	1000	35.87	34.23	36.03
1	0	0.5	0.0201	75%	3674	1224	1600	34.8	33.58	38.15
1	0	0.5	0.0201	75%	3674	1224	2300	33.33	36.19	37.25
1	0	0.5	0.0201	75%	3674	1224	3100	33.09	38.56	37.99
1	0	0.5	0.0201	75%	3674	1224	4000	32.27	39.54	40.11
1	0	0.5	0.0201	75%	3674	1224	5000	32.03	39.54	39.62
2	0	0.5	0.0201	75%	3674	1224	100	26.23	27.29	25.65
2	0	0.5	0.0201	75%	3674	1224	500	10.87	37.99	38.32
2	0	0.5	0.0201	75%	3674	1224	1000	36.85	37.17	39.05
2	0	0.5	0.0201	75%	3674	1224	1600	40.2	41.75	41.09
2	0	0.5	0.0201	75%	3674	1224	2300	42.57	42.4	42.08
2	0	0.5	0.0201	75%	3674	1224	3100	43.38	43.87	43.55
2	0	0.5	0.0201	75%	3674	1224	4000	44.77	43.87	44.44
2	0	0.5	0.0201	75%	3674	1224	5000	45.26	44.28	45.18
3	0	0.5	0.0201	75%	3674	1224	100	18.46	18.55	18.55
3	0	0.5	0.0201	75%	3674	1224	500	40.44	39.38	39.87
3	0	0.5	0.0201	75%	3674	1224	1000	39.05	39.13	39.22
3	0	0.5	0.0201	75%	3674	1224	1600	38.97	39.46	39.3
3	0	0.5	0.0201	75%	3674	1224	2300	41.75	40.93	41.58
3	0	0.5	0.0201	75%	3674	1224	3100	42.97	42.89	42.57
3	0	0.5	0.0201	75%	3674	1224	4000	42.32	43.63	42.57
3	0	0.5	0.0201	75%	3674	1224	5000	42.32	43.63	42.57
4	0	0.5	0.0201	75%	3674	1224	100	27.12	24.92	30.39
4	0	0.5	0.0201	75%	3674	1224	500	35.78	38.24	29.33
4	0	0.5	0.0201	75%	3674	1224	1000	42.97	36.76	35.13
4	0	0.5	0.0201	75%	3674	1224	1600	42.08	39.54	34.89
4	0	0.5	0.0201	75%	3674	1224	2300	40.44	40.44	33.91
4	0	0.5	0.0201	75%	3674	1224	3100	41.42	38.4	33.99
4	0	0.5	0.0201	75%	3674	1224	4000	43.87	38.73	34.64
4	0	0.5	0.0201	75%	3674	1224	5000	40.2	38.4	33.17
5	0	0.5	0.0201	75%	3674	1224	100	28.02	25.25	23.37
5	0	0.5	0.0201	75%	3674	1224	500	42.08	38.73	39.62
5	0	0.5	0.0201	75%	3674	1224	1000	39.95	38.32	38.48
5	0	0.5	0.0201	75%	3674	1224	1600	42.81	41.67	41.5
5	0	0.5	0.0201	75%	3674	1224	2300	43.71	42.32	42.32
5	0	0.5	0.0201	75%	3674	1224	3100	45.59	42.97	42.57
5	0	0.5	0.0201	75%	3674	1224	4000	44.53	43.22	43.38
5	0	0.5	0.0201	75%	3674	1224	5000	44.53	43.22	43.38
6	0	0.5	0.0201	75%	3674	1224	100	20.42	20.42	20.42
6	0	0.5	0.0201	75%	3674	1224	500	41.18	41.18	41.09
6	0	0.5	0.0201	75%	3674	1224	1000	42.89	43.06	43.14
6	0	0.5	0.0201	75%	3674	1224	1600	43.63	43.46	43.71
6	0	0.5	0.0201	75%	3674	1224	2300	42.65	42.81	43.14
6	0	0.5	0.0201	75%	3674	1224	3100	42.24	41.58	42.81
6	0	0.5	0.0201	75%	3674	1224	4000	42.24	42.81	42.4
6	0	0.5	0.0201	75%	3674	1224	5000	42.24	42.81	42.4
7	0	0.5	0.0201	75%	3674	1224	100	26.23	31.45	21.65
7	0	0.5	0.0201	75%	3674	1224	500	33.09	33.5	33.74

7	0	0.5	0.0201	75%	3674	1224	1000	35.05	34.31	33.91
7	0	0.5	0.0201	75%	3674	1224	1600	36.27	34.31	33.17
7	0	0.5	0.0201	75%	3674	1224	2300	37.99	34.07	36.19
7	0	0.5	0.0201	75%	3674	1224	3100	37.66	37.17	35.13
7	0	0.5	0.0201	75%	3674	1224	4000	37.99	35.46	38.4
7	0	0.5	0.0201	75%	3674	1224	5000	37.99	36.19	37.99

