

IMPLEMENTASI *LEARNING VECTOR QUANTIZATION* UNTUK DIAGNOSA PENYAKIT *DIABETES MELLITUS*

Fajar Rohman Hariri¹⁾

¹⁾ Teknik Informatika Universitas Nusantara PGRI Kediri

Jl. KH. Achmad Dahlan 76 Kediri

email : ojecxz@gmail.com

Abstrak

Jumlah penderita *Diabetes Mellitus* meningkat dari tahun ke tahun. Hal ini dikarenakan keterlambatan diagnosis penyakit tersebut. Penderita penyakit tersebut biasanya meninggal akibat komplikasi. Oleh karena itu perlu dilakukan tindakan guna mengantisipasi meningkatnya jumlah penderita *Diabetes Mellitus* yang meninggal. Dalam penelitian ini, dibuat suatu sistem pendukung keputusan penentuan penyakit *Diabetes Mellitus* menggunakan Metode *Learning Vector Quantization (LVQ)*. Variabel-variabel pendukung penegakan diagnosis seperti kadar glukosa darah puasa, kadar glukosa plasma puasa, kadar glukosa plasma tidur, kadar insulin, kadar HbA1c, kadar kolesterol HDL, kadar trigliserida, dan umur digunakan sebagai data learning, dan hasil diagnosa data learning ditetapkan sebagai target awal. Hasil dari proses pembelajaran menggunakan LVQ berupa bobot yang akan digunakan untuk proses klasifikasi dengan menghitung jarak suatu data terhadap tiap bobot menggunakan *Euclidean distance*, selanjutnya dibandingkan, yang terkecilah pemenangnya. Ada 3 class berupa diagnosa pasien tersebut mengidap *Diabetes Melitus type 1*, *Diabetes Melitus type 2* atau *Negatif Diabetes*. Dengan 300 data learning, 100 untuk tiap class, didapatkan bobot yang selanjutnya dipakai untuk klasifikasi data. Dari hasil penelitian diketahui bahwa range data sangat berpengaruh terhadap hasil pengenalan. Dari berbagai macam variasi ujicoba didapatkan hasil akurasi terbaik sebesar 86% dari 300 data learning dan 100 data ujicoba.

Kata kunci : *Learning Vector Quantization, Diabetes Mellitus, Sistem Pendukung Keputusan*

1. Pendahuluan

Menurut Prof. Dr. Sidartawan Soegondo, Indonesia menjadi negara keempat di dunia yang memiliki angka Diabetesi terbanyak. Diabetesi secara keseluruhan di Indonesia mengalami peningkatan hingga 14 juta orang. Hal ini berdasarkan laporan dari WHO, dimana pada jumlah diabetesi di Indonesia pada tahun 2000 adalah 8,4 juta orang setelah India (31,7 juta), Cina (20,8 juta) dan Amerika Serikat (17,7 juta). Diperkirakan jumlah tersebut akan meningkat pada tahun 2030, India (79,4 juta), Cina (42,3 juta), Amerika Serikat (30,3 juta) dan Indonesia (21,3 juta).[1]

Peningkatan jumlah diabetesi disebabkan keterlambatan penegakan diagnosis penyakit tersebut. Pasien sudah meninggal akibat komplikasi sebelum adanya penegakan diagnosis [2]. Sebanyak 75% penderita diabetesi meninggal akibat adanya komplikasi karena keterlambatan dalam penegakan penyakitnya [3]. Penyebab keterlambatan penegakan diagnosis tersebut adalah banyaknya faktor yang berpengaruh terhadap pilihan-pilihan yang ada atau beragamnya variabel.

Oleh karena itu, perkembangan teknologi informasi dan komunikasi (ICT) menjadi media utama untuk menjembatani permasalahan tersebut. Di bidang medis, peranan ICT dikemas dalam suatu wadah informatika medis. Ilmu informatika medis adalah ilmu yang menggunakan alat-alat bantu analisis sistem untuk mengembangkan prosedur (algoritma) untuk manajemen, kontrol proses, pembuatan keputusan, dan analisis keilmuan dari pengetahuan medis [4].

Dalam penelitian ini juga dicoba untuk membuat perangkat lunak yang dapat dipergunakan untuk mendiagnosa *Diabetes Melitus* menggunakan metode *Learning Vector Quantization (LVQ)*, algoritma ini dikenal dengan kemampuannya dalam klasifikasi yang mempunyai tingkat akurasi tinggi dan kecepatan dalam hal proses [5]. Sehingga *Learning Vector Quantization (LVQ)* dirasa penulis tepat untuk digunakan sebagai metode klasifikasi dalam penelitian ini.

Ada 8 variabel yang digunakan, yaitu kadar glukosa darah puasa, kadar glukosa plasma puasa, kadar glukosa plasma tidur, kadar insulin, kadar HbA1c, kadar kolesterol HDL, kadar trigliserida, dan umur. Dan data - data diagnosa pasien dikelompokkan menjadi 3 class. yaitu *Negatif Diabetes*, *Positif Diabetes tipe 1* dan *Positif Diabetes tipe 2*

2. Tinjauan Pustaka

2.1 Penelitian Sebelumnya

Penelitian sistem pendukung keputusan diagnosa penyakit *Diabetes Melitus* sebelumnya adalah sistem pendukung keputusan diagnosa penyakit *Diabetes Melitus* menggunakan metode sugeno yang dilakukan oleh Mariani Valentina Tampubolon pada tahun 2010. Penelitian yang dimanfaatkan untuk alat bantu medis dalam penegakan diagnosis *Diabetes Melitus* dengan metode Sugeno.

Dengan data inputan seperti kadar glukosa darah puasa, kadar glukosa plasma puasa, kadar glukosa plasma tidur, kadar glukosa darah 2 jam PP, kadar insulin, kadar HbA1c, kadar kolesterol HDL, kadar trigliserida dan umur. Dihasilkan sebuah Fuzzy Inference System dan diolah menggunakan metode Fuzzy Sugeno. Output berupa hasil diagnosa pasien positif Diabetes Type 1, positif Diabetes Type 2, pradiabetes atau negatif diabetes. Dengan menggunakan metode inferensi model Sugeno dalam penentuan penyakit Diabetes Mellitus, diperoleh hasil yang sama antara hasil sistem dengan hasil perhitungan manual [6].

Penelitian kali ini menggunakan metode *Learning Vector Quantization*, untuk perhitungan, dalam metode ini ada proses *learning* didalamnya, berbeda dengan penelitian sebelumnya yang menggunakan metode Fuzzy Sugeno yang di dalamnya tidak ada proses learning, dan saat dicoba ternyata ada beberapa kondisi yang tidak cocok. Dalam penelitian - penelitian sebelumnya kebanyakan LVQ digunakan untuk klasifikasi citra. Maka dari itu, penelitian ini mencoba menggunakan LVQ dalam hal sistem pendukung keputusan. Dengan metode tersebut akan menghasilkan bobot yang merepresentasikan keseluruhan data, yang selanjutnya akan digunakan untuk proses klasifikasi data baru.

2.2 Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) adalah sistem pemroses informasi yang memiliki karakteristik unjuk kerja tertentu yang menyerupai jaringan syaraf biologis. JST telah dikembangkan sebagai generalisasi model matematika dari aspek kognitif manusia atau syaraf biologis, yaitu didasarkan pada asumsi-asumsi bahwa [7]:

- Pemrosesan informasi terjadi pada elemen-elemen yang disebut *neuron*.
- Sinyal-sinyal merambat di antara neuron melalui interkoneksi.
- Setiap interkoneksi memiliki bobot yang bersesuaian yang pada kebanyakan jaringan syaraf berfungsi untuk mengalikan sinyal yang dikirim.
- Setiap neuron menerapkan fungsi aktifasi (biasanya tidak linear) pada masukan jaringan untuk menentukan sinyal keluarannya

2.2.1 Metode Klasifikasi *Learning Vector Quantization* (LVQ)

Jaringan saraf tiruan *Learning Vector Quantization* (LVQ) telah banyak dimanfaatkan untuk pengenalan pola baik berupa citra, suara, dan lain-lain. Jaringan LVQ sering pula digunakan untuk ekstraksi ciri (*feature*) pada proses awal pengenalan pola. Metode Jaringan Syaraf LVQ termasuk dengan *Supervised Learning* dalam penentuan bobot / model pembelajarannya, dimana pada metode LVQ ditentukan hasil seperti apa selama proses

pembelajaran. Selama proses pembelajaran nilai bobot disusun dalam suatu range tertentu tergantung pada nilai input yang diberikan. Tujuan pembelajaran ini adalah pengelompokan unit-unit yang hampir sama dalam satu area tertentu. Pembelajaran seperti ini sangat cocok untuk pengelompokan (klasifikasi) pola.

Prinsip kerja dari algoritma LVQ adalah pengurangan node-node tetangganya (*neighbour*) [8], sehingga pada akhirnya hanya ada satu node *output* yang terpilih (*winner node*). Pertama kali yang dilakukan adalah melakukan inialisasi bobot untuk tiap-tiap *class*. Setelah diberikan bobot, maka jaringan diberi input sejumlah dimensi node/neuron input. Setelah input diterima jaringan, maka jaringan mulai melakukan perhitungan jarak vektor yang didapatkan dengan menjumlah selisih/jarak antara vektor input dengan vektor bobot menggunakan *Euclidean distance*. Secara matematis *Euclidean Distance* dapat dirumuskan [9] :

$$d_j^2 = \sum_{i=0}^{n-1} (X_i(t) - W_{ij}(t))^2$$

dimana : $d_j^2 = \text{distance}$

$X_i = \text{Node data input}$

$W_{ij} = \text{Bobot ke-ij}$

Setelah diketahui tiap-tiap jarak antara *nodeoutput* dengan *input* maka dilakukan perhitungan jumlah jarak selisih *minimum*. Dimana *node* yang terpilih (*winner*) berjarak minimum akan di update bobot, update bobot *node winner* yang dirumuskan sebagai berikut [9] :

Jika sesuai target memakai rumus:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t) \cdot (x_i(t) - w_{ij}(t)), j \in N_e$$

dan jika tidak

$$w_{ij}(t+1) = w_{ij}(t) - \alpha(t) \cdot (x_i(t) - w_{ij}(t)), j \in N_e$$

$$0 < \alpha(t) < 1$$

Dimana :

x = Input pixel

w = bobot

N_e = Nilai *neighborhood*

t = waktu

i = index node input

j = index node output

= alpha learning rate

(t) merupakan *alpha/learning rate* yaitu faktor pengali pada perubahan bobot yang berubah terhadap perubahan *error*. Perubahan *alpha* ini sesuai dengan banyaknya *input* yang masuk. Faktor pengali *alpha/learningrate* ini akan selalu

berkurang bila tidak ada perubahan *error*. Dalam penelitian ini *alphalearningrate* akan berubah berkurang secara geometris sebagai berikut [10] :

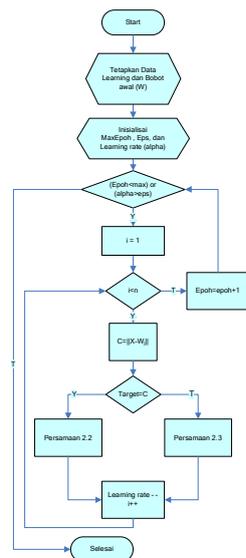
$$\alpha(t + 1) = 0.1 * \alpha(t)$$

Secara garis besar algoritma *Learning Vector Quantization (LVQ)* sebagai berikut[10]:

1. Siapkan data learning, x (m,n) dan target T (1,n).
2. Inisialisasi bobot (W), maksimum epoh (Max Epoh), error minimum yang diharapkan (Eps), *learning rate* (). Max Epoh dan *learning rate* digunakan untuk menentukan batas ambang komputasi
3. Melakukan proses sebagai berikut selama (epoh<makEpoh) atau (>eps).
 - a. epoh = epoh+1
 - b. Kerjakan untuk i=1 sampai n
 - Tentukan j sedemikian rupa sehingga $\|X-W_j\|$ minimum (Sebut sebagai C_j)
 - Perbaiki W_j dengan ketentuan
 - o Jika $T=C_j$ maka : $W_j(\text{baru})=W_j(\text{lama}) + (X-W_j(\text{lama}))$
 - o Jika $T \neq C_j$ maka : $W_j(\text{baru})=W_j(\text{lama}) - (X-W_j(\text{lama}))$
 - c. Kurangi nilai
4. Kembali ke langkah ke-3, jika (epoh<makEpoh) atau (>eps) tidak terpenuhi, selesai.

Setelah dilakukan pelatihan, akan diperoleh bobot akhir (W). Bobot-bobot ini nantinya akan digunakan untuk melakukan klasifikasi terhadap data baru.

Berikut merupakan flowchart LVQ ditunjukkan pada gambar 1.



Gambar 1. Flowchart LVQ

2.3 Diabetes Mellitus

Menurut *American Diabetes Association (ADA)* 2003, Diabetes Melitus merupakan suatu kelompok metabolik dengan karakteristik hiperglikemia yang terjadi karena kelainan sekresi insulin, kerja insulin atau kedua-duanya. Hiperglikemia kronik pada Diabetes berhubungan dengan kerusakan jangka panjang, disfungsi dan kegagalan beberapa organ tubuh, terutama mata, ginjal, syaraf, jantung dan pembuluh darah.

Sebelumnya *World Health Organization (WHO)* menyatakan bahwa Diabetes Mellitus merupakan suatu yang tidak dapat dituangkan dalam satu jawaban yang jelas dan singkat tetapi secara umum dapat dikatakan sebagai suatu kumpulan problema anatomik dan kimiawi yang merupakan akibat dari sejumlah faktor di mana didapat defisiensi insulin absolute atau relatif dan gangguan fungsi insulin.[11]

Diabetes mellitus (DM) didefinisikan sebagai suatu penyakit atau gangguan metabolisme kronis dengan multi etiologi yang ditandai dengan tingginya kadar gula darah disertai dengan gangguan metabolisme karbohidrat, lipid dan protein sebagai akibat insufisiensi fungsi insulin. Insufisiensi fungsi insulin dapat disebabkan oleh gangguan atau defisiensi produksi insulin oleh sel-sel beta Langerhans kelenjar pankreas, atau disebabkan oleh kurang responsifnya sel-sel tubuh terhadap insulin[12].

Pengertian penyakit Diabetes Mellitus bisa dipermudah dengan mempelajari star player Diabetes Mellitus. Hormon berfungsi sebagai *board of directors* dalam kaitan dengan metabolisme, yaitu mengarahkan dan mengendalikan kegiatan. *Board of directors* mempunyai representasi pankreas (insulin dan glukagon), kelenjar hipofisis (GH dan ACTH), korteks adrenal (kortisol), sistem saraf autonomik (norepinefrin) dan medulla adrenal (epinefrin).

Dari semua hormon yang terkait dalam metabolisme glukosa, hanya insulin yang bisa menurunkan gula darah. Hormon yang lain adalah "*counterregulatory hormones*" karena bisa membuat gula darah meningkat. Insulin adalah hormon yang kurang (absolut atau relatif) dalam penyakit Diabetes Mellitus. Hormon insulin disintesis (dihasilkan) oleh sel beta Pulau Langerhans yang terdapat pada pankreas. Peran insulin adalah melihat bahwa sel tubuh dapat memakai bahan bakar. Insulin berperan sebagai "kunci" yang bisa membuka pintu sel agar bahan bakar bisa masuk ke dalam sel. Pada permukaan setiap sel terdapat reseptor (oleh insulin), glukosa dan asam amino bisa masuk ke dalam sel tubuh.

3. Metode Penelitian

Dalam penelitian ini dilakukan pengumpulan data-data pasien diabetes mellitus yang diperoleh dari

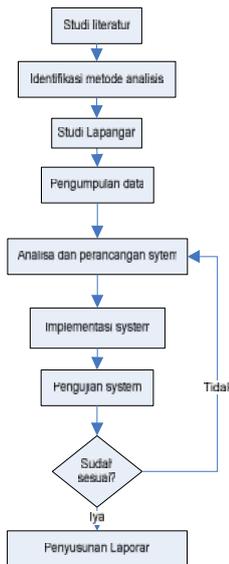
hasil data laboratorium dari pasien periode tahun 2010 RSUD Sidoarjo. Untuk data learning, ada 100 data untuk masing-masing class, dan ada 3 class, jadi total data learning 300. Untuk data ujicoba ada 100 data, 40 untuk Negatif Diabetes, dan masing-masing 30 untuk Diabetes Type 1 dan Type 2.

Survey atau pengamatan di lakukan untuk mendapatkan gambaran secara umum tentang data pasien Diabetes dan pengelompokan penyakit Diabetes Mellitus di Rumah Sakit. Hal ini akan memudahkan identifikasi permasalahan dalam perancangan sistem . Pengamatan di lakukan dengan survey dan wawancara kepada pihak Rumah Sakit Umum Daerah Sidoarjo.

Teknik pengumpulan data dilakukan dengan melihat hasil rekam medik dan hasil laboratorium pasien.

Untuk atribut – atribut dari hasil diagnosa yang digunakan dalam penelitian ini didasarkan atas data yang tersedia di rumah sakit, beberapa penelitian sebelumnya dan wawancara dengan perawat dan pihak lab.

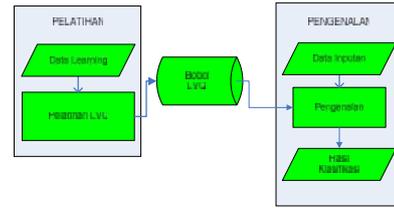
Gambaran langkah – langkah yang di tempuh dalam menjalankan penelitian di jelaskan pada gambar 2 di bawah ini:



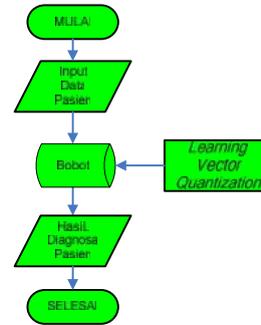
Gambar 2. Flowchart metodologi penelitian

3.1 Perancangan Sistem

Dalam system ini, pertama kita menetapkan bobot awal, kemudian dengan metode LVQ akan dilakukan proses *learning* yang selanjutnya didapatkan bobot terakhir untuk tiap *class*, yang merupakan gambaran dari masing-masing *class*. Kemudian bobot tersebut akan digunakan untuk mengklasifikasi data baru. Gambaran sistem dan desain aplikasi ditunjukkan pada gambar 3 dan 4.



Gambar 3. Gambaran Umum Sistem



Gambar 4. Flowchart Desain Aplikasi

Garis besar sistem terbagi menjadi proses pelatihan dan proses pengenalan. Hasil akhir dari metode LVQ adalah bobot pelatihan yang disimpan ke dalam *database/file*. Berikut perincian proses pelatihan :

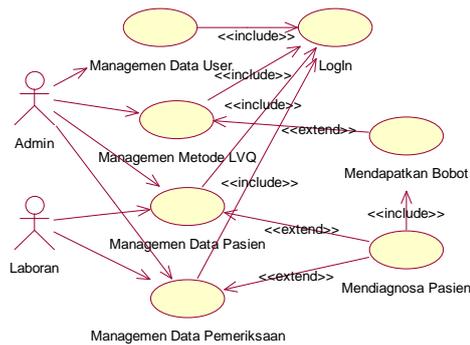
- a. Data learning dengan variabel glukosa darah puasa, kadar glukosa plasma puasa, kadar glukosa plasma tidur, kadar insulin, kadar HbA1c, kadar kolesterol HDL, kadar trigliserida, umur dan indek. Indek merupakan hasil dari data tersebut masuk di *class* yang mana.
- b. Selanjutnya data learning diproses menggunakan metode LVQ, dan akan dihasilkan bobot yang digunakan untuk proses pelatihan.
- c. Hasil bobot LVQ disimpan dalam media penyimpanan (*database* atau *file*)

Untuk Proses Pengujian sebagai berikut :

- a. Inputan berupa diagnosa pasien dengan variabel glukosa darah puasa, kadar glukosa plasma puasa, kadar glukosa plasma tidur, kadar insulin, kadar HbA1c, kadar kolesterol HDL, kadar trigliserida dan umur.

Dengan menggunakan *Euclidean distance* data inputan dihitung dengan bobot yang dihasilkan dari metode LVQ, maka akan didapatkan data inputan tersebut termasuk *class* yang mana.

Pada gambar 5, *use case* dibawah ini menggambarkan kegiatan-kegiatan yang dilakukan oleh tiap-tiap user dalam sistem ini.



Gambar 5. Use Case Diagram

4. Hasil dan Pembahasan

Dilakukan uji coba terhadap pengenalan dengan 100 data ujicoba, dan dilakukan dengan learning rate antara 0,01 – 0,1 , keakurasiannya ditunjukkan pada tabel 1 berikut:

Tabel 1. Akurasi learning rate 0,01 – 0,1 satuan HbA1c dan insulin %

No	Learning rate	Akurasi Pengenalan
1	0,01	68%
2	0,02	69%
3	0,03	69%
4	0,04	69%
5	0,05	69%
6	0,06	69%
7	0,07	69%
8	0,08	69%
9	0,09	69%
10	0,1	69%

Kesemuanya memiliki akurasi yang hampir sama, yaitu 68% untuk learning rate 0,01 dan yang lain 69%. Namun saat melihat hasil keakurasiannya yang hanya 69%. Dan dengan melihat data yang ada, ada hipotesa sementara penulis yang didapat dari hasil ujicoba dari 100 data di atas, juga membandingkan keakurasiannya dari penelitian-penelitian sebelumnya, bahwa metode LVQ ada kelemahannya, yaitu metode ini kurang bagus untuk data yang tiap atributnya memiliki range yang tidak sama. Sehingga perubahan nilai yang sama akan membawa pengaruh yang berbeda.

Untuk membuktikan hipotesa sementara yang didapat saat ujicoba, penulis mencoba untuk mengganti satuan HbA1c dan insulin dari % menjadi $\frac{0}{100}$. Jadi misal data sebelumnya insulin 2%, maka dirubah menjadi 20 $\frac{0}{100}$. Sehingga selisih yang sebelumnya satuan akan menjadi puluhan. Setelah itu dilakukan ujicoba terhadap 100 data yang ada, dan didapatkan akurasi yang ditunjukkan pada tabel 2 sebagai berikut:

Tabel 2. Akurasi untuk learning rate 0,01 – 0,1 satuan $\frac{0}{100}$

No	Learning rate	Akurasi Pengenalan
1	0,01	86%
2	0,02	86%
3	0,03	86%
4	0,04	86%
5	0,05	86%
6	0,06	86%
7	0,07	86%
8	0,08	86%
9	0,09	86%
10	0,1	86%

Ternyata hipotesa yang didapat terbukti, setelah satuan diganti, akurasi bertambah, dari yang sebelumnya hanya 69% menjadi 82%. Oleh karena itu, selanjutnya penelitian ini menggunakan satuan $\frac{0}{100}$ untuk HbA1c dan insulin, namun saat input data tetap %, sistem yang akan mengkonversinya.

Untuk mengetahui hasil terbaik, selanjutnya dilakukan ujicoba dengan data learning sebanyak 25% , 50%, dan 75% dari keseluruhan data, dan selanjutnya dilakukan ujicoba dengan data learning diubah menjadi data cek juga sebaliknya. Ujicoba dilakukan dengan nilai *learning rate* 0,01 dan *MaxEpoch* 100.

- Data Learning 25% (100 data)
 Dilakukan ujicoba dengan data Learning sebanyak 100 dan data ujicoba sebanyak 300, dan dilakukan swap antara data learning dan ujicoba.
- Data Learning 50% (200 data)
 Dilakukan ujicoba dengan data Learning sebanyak 200 dan data ujicoba sebanyak 200, dan dilakukan swap antara data learning dan ujicoba.
- Data Learning 75% (300 data)
 Dilakukan ujicoba dengan data Learning sebanyak 300 dan data ujicoba sebanyak 100, dan dilakukan swap antara data learning dan ujicoba.

Dilakukan ujicoba dengan data Learning sebanyak 300 dan data ujicoba sebanyak 100, dan dilakukan swap antara data learning dan ujicoba.

Dari beberapa skenario ujicoba diatas dihasilkan akurasi bisa dilihat di tabel 3 sebagai berikut:

Tabel 3. Akurasi untuk jumlah data learning yang berbeda

Jumlah Data Learning	Jumlah Data Pelatihan			Akurasi
	DM Type 1	DM Type 2	Negatif DM	
300	98	96	106	86 %
200	64	64	72	74,5 %
100	30	30	60	55 %

Tabel 4. Akurasi untuk swap data learning dan ujicoba

Ujicoba	Akurasi	
	Normal	Swap
Data Learning 25%	55 % (165/300)	81% (81/100)
Data Learning 50%	74,5% (149/200)	64% (128/200)
Data Learning 75%	86% (86/100)	57% (171/300)

Tabel 5. Akurasi untuk jumlah data learning dan ujicoba yang berbeda

Data Learning	Data Ujicoba	Akurasi
100	100	59 %
100	200	58,5 %
100	300	55%
200	100	76
200	200	74,5 %
300	100	86%

Pada Tabel 4 dan 5 menunjukkan hasil pengenalan variasi data training dan data ujicoba. Dari sana terlihat, bahwa dalam penelitian ini, semakin banyak data learning maka akan menghasilkan akurasi yang lebih baik. Hasil terbaik diperoleh dari 300 data learning yang berhasil mengenali 86 data dari 100 data ujicoba.

Dari ujicoba dengan nilai learning rate antara 0,01 – 0,1 dan dengan range 0,01 menghasilkan akurasi yang sama. Karena nilai learning rate adalah antara 0-1. Maka dilakukan ujicoba selanjutnya dengan nilai learning rate 0,1-1 dengan range 0,1. Hasil akurasi tiap learning rate terdapat pada tabel 6 berikut:

Tabel 6. Akurasi untuk learning rate 0,1 – 1 satuan $\frac{0}{100}$

No	Learning rate	Akurasi Pengenalan
1	0,1	86%
2	0,2	86%
3	0,3	46%
4	0,4	28%
5	0,5	28%
6	0,6	28%
7	0,7	28%
8	0,8	28%
9	0,9	28%
10	1	28%

Untuk learning rate 0,1 – 0,2 memiliki akurasi yang sama, yaitu 86%, namun saat nilainya 0,3 akurasi menjadi 46% dan semakin besar learning rate, semakin berkurang akurasinya.

Oleh karena itu, untuk mengetahui nilai learning rate yang bagus, dilakukan ujicoba lagi dengan nilai learning rate antara 0,2 - 0,3 dengan range 0,01. Hasil akurasi bisa dilihat pada tabel 7 berikut:

Tabel 7. Akurasi untuk learning rate 0,21 – 0,3

No	Learning rate	Akurasi Pengenalan
1	0,21	86%
2	0,22	86%
3	0,23	86%
4	0,24	86%
5	0,25	86%
6	0,26	45%
7	0,27	45%
8	0,28	45%
9	0,29	34%
10	0,3	45%

Dari hasil ujicoba, antara nilai 0,21 – 0,25 menghasilkan akurasi yang sama, yaitu 86% , dan dengan selanjutnya learning rate 0,26 menghasilkan akurasi 45%. Jadi hasil terbaik didapatkan pada learning rate antara 0,01 – 0,25 dengan akurasi 86%. Tabel 8 berikut menunjukkan jumlah data yang bisa dikenali untuk masing – masing class

Tabel 8. Jumlah data yang bisa dikenali

Jumlah data yang berhasil dikenali untuk class -		
Negatif Diabetes (34)	DM Type 1 (33)	DM Type 2 (33)
26 (76,4%)	29 (87,8%)	31 (93,3%)

Satuan atau range data sangat mempengaruhi hasil dari akurasi metode Learning Vector Quantization. Dari 300 data learning, maxEpoch 200 dan dengan penggantian satuan insulin dari % menjadi $\frac{0}{100}$ menghasilkan akurasi yang lebih baik, yakni sebesar 86% dibanding sebelumnya yang hanya 68%-69%.

Dari beberapa skenario ujicoba, dengan variasi jumlah data learning dan ujicoba, menghasilkan akurasi yang berbeda pula. Dan dalam penelitian ini, semakin banyak data learning, maka akan semakin baik akurasinya. Hasil terbaik diperoleh dengan menggunakan 300 data learning, dan dari 100 data ujicoba, metode LVQ berhasil mengenali 86 data.

Didapatkan hasil terbaik menggunakan learning rate antara 0,01 – 0,25. Untuk nilai learning rate antara 0,01 – 0,25 paling baik dalam mengenali data untuk DM Type 2, dari 33 data berhasil mengenali 31 (93,3%). Namun kurang bagus dalam mengenali data Negatif Diabetes, dari 34 data, hanya bisa mengenali 26 (76,4%).

5. Kesimpulan dan Saran

Dari hasil percobaan dapat diketahui bahwa metode LVQ kurang bagus apabila digunakan untuk data yang range untuk tiap attribute datanya tidak sama, sehingga perubahan nilai yang sama akan membawa pengaruh yang berbeda untuk tiap attribute. Dalam sistem pendukung keputusan penentuan penyakit Diabetes

Mellitus ini, dilakukan pergantian satuan untuk insulin menjadi $\frac{0}{100}$. Dan dengan metode LVQ ini menghasilkan akurasi sebesar 86% untuk learning rate 0,01 – 0,25 dari yang sebelumnya bila menggunakan satuan % hanya bisa mengenali 69% data. Jadi range antar data untuk tiap atribut sangat mempengaruhi hasil pengenalan metode LVQ.

Dari berbagai macam variasi uji coba dari jumlah data learning dan data ujicoba, menghasilkan akurasi yang berbeda pula. Dan dalam penelitian ini, semakin banyak data learning, maka akan semakin baik akurasinya. Hasil terbaik diperoleh dengan menggunakan 300 data learning, dan dari 100 data ujicoba, metode LVQ berhasil mengenali 86 data. Dengan rincian untuk DM Type 2, dari 33 data berhasil mengenali 31 (93,3%), DM Type 1, dari 33 data berhasil mengenali 29 (87,8%), Negative DM, dari 34 data berhasil mengenali 26 (76,4%).

Aplikasi untuk penentuan penyakit Diabetes Mellitus ini sudah baik, namun ada baiknya dikembangkan dengan menggunakan metode yang berbeda atau dikombinasi dengan metode lain. Dan untuk data learning ditambah supaya bisa menghasilkan akurasi yang lebih baik.

Daftar Pustaka

- [1] Darmono. 2005. *Pengaturan Pola Hidup Penderita Diabetes Untuk Mencegah Komplikasi Kerusakan Organ-Organ Tubuh*. Semarang: Universitas Diponegoro. <URL: eprints.undip.ac.id/331/1/Darmono.pdf> (Diakses tanggal 10 Januari 2012)
- [2] Sudoyo. 2006. *Buku Ajar Ilmu Penyakit Dalam*. Jakarta: Pusat Penerbitan Departemen Ilmu Penyakit Dalam FKUI.
- [3] Price, Sylvia A., Wilson, Lorraine M. 2006. *PATOFISIOLOGI Konsep Klinis Proses-Proses Penyakit*. Jakarta: Penerbit Buku Kedokteran EGC.
- [4] Kusumadewi, Sri. 2009. *Aplikasi Informatika Medis Untuk Penatalaksanaan Diabetes Mellitus Secara Terpadu*. Seminar Nasional Aplikasi Teknologi Informasi 2009 (SNATI2009) ISSN:1907-5022 <http://journal.uin.ac/index.php/Snati/article/viewFile/1175/1003>. (Diakses 25 November 2011)
- [5] Hadnanto, M.A., 1996. *Perbandingan Beberapa Metode Algoritma JST untuk Pengenalan Pola Gambar*. Tugas Akhir. Surabaya : Lab. Teknik Elektronika ITS Surabaya.
- [6] Tampubolon, Mariani Valentina. 2010. *Sistem Pendukung Keputusan Penentuan Penyakit Diabetes Mellitus Dengan Metode Sugeno*. Skripsi : Universitas Sumatera Utara.
- [7] Kusumadewi, Sri. 2003. *Artificial Intelligence: Teknik & Aplikasinya*. Yogyakarta: Graha Ilmu.
- [8] Kusumadewi, S. 2004. *Membangun Jaringan Syaraf Tiruan menggunakan Matlab dan Excel Link*. Yogyakarta: Graha Ilmu.
- [9] Effendy, N., Imanto, R., 2009. *Deteksi Pornografi Pada Citra Digital Menggunakan Pengolahan Citra Dan Jaringan Saraf Tiruan*, <URL: http://www.undip.ac.id/files/2010/02/deteksi-pornografi.pdf >. (Diakses pada tanggal 3 Januari 2011).
- [10] Balza, A., Kartika, F. 2005. *Teknik Pengolahan Citra Digital*. Yogyakarta: Andi Publishing.
- [11] Soegondo, 2004, *Diabetes Mellitus, Penatalaksanaan Terpadu*. Jakarta : Balai Penerbitan FKUI.

- [12] Direktorat Bina Farmasi Komunitas dan Klinik Direktorat Jenderal Bina Kefarmasian dan Alat Kesehatan Departemen Kesehatan RI, *Pharmaceutical Care Untuk Penyakit Diabetes Mellitus* <URL: http://piofamul.com/wp-content/uploads/2010/09/pharmaceutical-care-diabetes-mellitus1.pdf> (Diakses 10 Januari 2012).

Biodata Penulis

Fajar Rohman Hariri, memperoleh gelar Sarjana Komputer (S.Kom), Program Studi Teknik Informatika Universitas Trunojoyo Madura, lulus tahun 2012. Saat ini sebagai Staf Pengajar Program Studi Teknik Informatika Universitas Nusantara PGRI Kediri

