

KLASIFIKASI *BEAT* ARITMIA PADA SINYAL EKG MENGGUNAKAN FUZZY WAVELET LEARNING VECTOR QUANTIZATION

Elly Matul Imah¹ dan T. Basaruddin²

¹Jurusan Matematika, FMIPA Universitas Negeri Surabaya, Jl. Ketintang, Surabaya, 60231 Indonesia

²Fakultas Ilmu Komputer, Universitas Indonesia, Kampus Baru UI Depok, Jawa Barat, 16424, Indonesia

E-mail: elly.matul@gmail.com

Abstrak

Pengenalan pola *beat* dalam analisa rekaman elektrokardiogram (EKG) menjadi bagian yang penting dalam deteksi penyakit jantung terutama aritmia. Banyak metode yang dikembangkan terkait dengan pengenalan pola *beat*, namun sebagian besar masih menggunakan algoritma klasifikasi klasik di mana masih belum mampu mengenali *outlier* klasifikasi. *Fuzzy Learning Vector Quantization* (FLVQ) merupakan salah satu algoritma yang mampu untuk mengenali *outlier* klasifikasi tetapi juga memiliki kelemahan untuk sistem uji yang bukan data berkelompok. Dalam tulisan ini peneliti mengusulkan *Fuzzy Wavelet Learning Vector Quantization* (FWLVQ), yaitu modifikasi FLVQ sehingga mampu mengatasi data *crisp* maupun data *fuzzy* dan juga memodifikasi inferensi sistemnya sebagai perpaduan model *fuzzy* Takagi Sugeno Kang dengan *wavelet*. Sinyal EKG diperoleh dari *database* MIT-BIH. Sistem pengenalan pola *beat* secara keseluruhan terbagi atas dua bagian yaitu data pra proses dan klasifikasi. Hasil percobaan diperoleh bahwa FWLVQ memiliki akurasi sebesar 90.20% untuk data yang tidak mengandung *outlier* klasifikasi dan 87.19% untuk data yang melibatkan *outlier* klasifikasi dengan rasio data uji *outlier* klasifikasi dengan data *non-outlier* sebesar 1:1.

Kata Kunci: *aritmia, EKG, FLVQ, fuzzy wavelet, FWLVQ*

Abstract

The recognition of beat pattern in analysis of recording an electrocardiogram (ECG) becomes an important detection of heart disease, especially arrhythmias. Many methods are developed related to the recognition of beat patterns, but most still use the classical classification algorithms which are still not able to identify outlier classification. Fuzzy Learning Vector Quantization (FLVQ) is one of the algorithms that can identify outlier classification but also has a weakness for test systems that are not grouped data. In this paper we propose a Fuzzy Wavelet Quantization Learning Vector (FWLVQ), which is modified so as to overcome FLVQ crisp data and fuzzy data and also modify the inference system as a combination of Takagi Sugeno Kang fuzzy model with the wavelet. ECG signal obtained from the MIT-BIH database. Beat pattern recognition system as a whole is divided into two parts: data pre-processing and classification. The experimental results obtained that FWLVQ has an accuracy 90.20% for data that does not contain outlier classification and 87.19% for the classification of data involving outlier ratio outlier test data classification with *non-outlier* data of 1:1.

Keywords: *arrhythmias, EKG, FLVQ, fuzzy wavelet, FWLVQ*

1. Pendahuluan

Elektrokardiogram (EKG) adalah sinyal yang menggambarkan aktivitas listrik yang dilakukan oleh jantung dan sangat penting dalam mendiagnosis penyakit jantung dan kondisi jantung. Ketidaknormalan aktivitas listrik pada jantung atau biasa dikenal dengan aritmia jantung, dapat diketahui dengan rekaman EKG. Dewasa ini, klasifikasi *beat* secara otomatis telah menjadi topik penelitian yang menarik karena dengan adanya klasifikasi pola *beat* secara otomatis akan sangat membantu ahli jantung dalam menemukan adanya *beat* aritmia dalam sekian

ratus bahkan ribuan *beat* yang didapat dari kertas EKG.

Banyak algoritma dikembangkan untuk memfasilitasi pengenalan *beat* tersebut baik dari sisi ekstraksi fitur hingga klasifikasi beberapa diantaranya dikembangkan dengan menggunakan Jaringan Syaraf Tiruan (JST) [1-4]. Kombinasi transformasi *wavelet* atau *Principal Component Analysis* (PCA) atau *Fuzzy C-Means* (FCM) dengan JST [5-7] dan mengaplikasikan *Bayesian framework* [8] juga banyak dikembangkan oleh para peneliti. Sebagian peneliti mengaplikasikan teori *fuzzy* untuk deteksi aritmia [9-11]. Kombinasi Algoritma Genetika [12] atau *Particle*

Swarm Optimization (PSO) dengan Support Vector Machine (SVM) [7][13][14] juga telah dikembangkan untuk pengenalan pola *beat* aritmia. Perbandingan beberapa metode ekstraksi fitur seperti PCA, transformasi *wavelet*, algoritma morfologi yang diimplementasikan dalam algoritma klasifikasi berbasis JST [15] dan SVM [16]. Ekstraksi fitur menggunakan algoritma morfologi juga dilakukan oleh Philips dan kawan-kawan [17]. Namun dari sekian banyak penelitian yang telah dilakukan oleh para peneliti dalam klasifikasi *beat*, masih jarang dijumpai adanya topik yang mengembangkan suatu algoritma yang mampu untuk mendeteksi adanya *outlier* klasifikasi.

Dalam penelitian ini akan dikembangkan suatu algoritma berbasis pada jaringan syaraf tiruan dan teori *fuzzy* yang mampu mengatasi masalah *outlier* klasifikasi. *Outlier* klasifikasi adalah data yang muncul pada saat uji coba di mana data tersebut bukan merupakan anggota bagian dari kelas *train*. Algoritma ini merupakan pengembangan dari *Fuzzy Learning Vector Quantization* [18-20] karena algoritma FLVQ mampu mengenali *outlier* klasifikasi tetapi tidak sesuai jika diaplikasikan untuk data sekuensial atau data *non-fuzzy*, sehingga peneliti mengembangkan dengan tetap mempertahankan kemampuan FLVQ mengatasi *outlier* klasifikasi tetapi juga dapat digunakan untuk data sekuensial. Modifikasi dalam penelitian ini juga melibatkan transformasi *wavelet* dalam proses penentuan keputusan *fuzzy* yang didasari oleh model *fuzzy* Takagi Sugeno Kang [21][22]. Pengembangan FLVQ dalam penelitian ini, peneliti mengolah menjadi *Fuzzy Wavelet Learning Vector Quantization* (FWLVQ).

Dalam penelitian ini peneliti menggunakan data aritmia dari MIT-BIH [23]. Tata penulisan dalam paper ini terbagi sebagai berikut, Bab II berisi tentang pra pemrosesan data EKG. Bab III berisi tentang FLVQ dan pengembangannya. Bab IV berisi tentang hasil percobaan dan bab V berisi kesimpulan dan rencana riset kedepannya.

2. Metodologi

Baseline Noise Reduction, tahapan pertama dalam pemrosesan sinyal EKG adalah *baseline noise reduction*. *Baseline Noise Reduction* atau ada yang menyebut dengan *baseline wander removal* adalah proses untuk estimasi dan menghilangkan *noise* dari *baseline* pada sinyal EKG. Dalam proses perekaman EKG sering terjadi adanya pergeseran garis sumbu sinyal EKG, sehingga sering menimbulkan permasalahan dalam diagnosa hasil rekaman EKG. Permasalahan pergeseran sumbu utama

tersebut masih menjadi *open problem* dalam pemrosesan sinyal EKG.

Dalam penelitian ini, peneliti melakukan estimasi pergeseran sumbu utama atau *baseline wander estimation* menggunakan interpolasi *cubic spline*. Pergeseran sumbu utama sinyal EKG diestimasi berdasarkan *ST segment* dari tiap *beat* dalam rekaman sinyal EKG [24]. Dengan menggunakan *ST segment* sebagai parameter untuk estimasi pergeseran sumbu utama menggunakan *cubic spline* maka proses untuk mendapatkan sumbu utama yang sebenarnya akan lebih mudah.

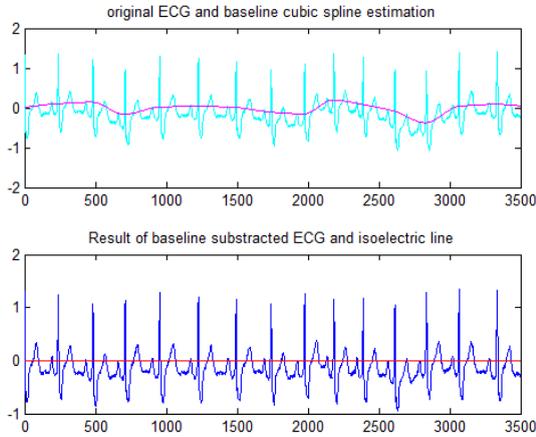
Metode interpolasi *cubic spline* adalah salah satu cara untuk *fitting* kurva pada data eksperimental yang bentuk dari fungsinya maupun turunannya tidak diketahui. Metode ini menggunakan polinomial pangkat tiga yang diasumsikan berlaku pada titik-titik yang terletak di antara dua titik data yang diketahui. Fungsi yang bersangkutan kemudian diaplikasikan pada semua titik-titik data yang ada, sehingga didapatkan persamaan simultan, yang selanjutnya dapat diselesaikan dengan menggunakan metode matriks.

Estimasi pergeseran sumbu utama dilakukan dengan interpolasi *cubic spline* karena interpolasi *cubic spline* menghasilkan suatu pendekatan yang lebih mulus dibandingkan dengan linier *spline* ataupun *quadratic spline* karena ada jaminan bahwa turunan pertama dan kedua adalah kontinu pada seluruh selang. Interpolasi *cubic spline* merupakan pendekatan fungsi yang diperoleh dengan menggunakan polinomial derajat tiga pada masing-masing sub selang.

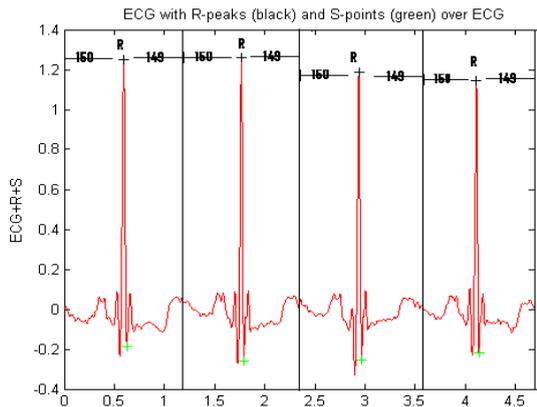
Dalam kasus sinyal EKG sub selang yang peneliti gunakan adalah *ST segment* dari tiap-tiap *beat*. Definisi dari *cubic spline* adalah sebagai berikut: Diberikan titik-titik data $(t_1, A_1), (t_2, A_2), \dots, (t_n, A_n)$, di mana titik data tersebut merupakan *ST segment* dari sinyal EKG. Suatu *cubic spline* S yang menginterpolasi data yang diberikan memenuhi sifat-sifat berikut: (1) dalam setiap selang $[x, x_{i+1}]$, di mana $i=1, 2, \dots, n-1$, dan S adalah polinomial derajat tiga. (2) $S(x_i)=f_i, i=1,2,\dots,n$. (3) S, S' dan S'' adalah kontinu di titik-titik dalam x_2, x_3, \dots, x_{n-1} .

Setelah diperoleh persamaan tersebut maka pergeseran sumbu utama bisa diestimasi dan langkah selanjutnya adalah mencari sumbu utama yang sebenarnya atau isoelektrik sinyal EKG dengan menentukan *pivolt* isoelektrik untuk digunakan sebagai pengurang sinyal EKG. Untuk lebih jelasnya dapat digambarkan pada gambar 1. Substraksi *Beat* Sinyal EKG, proses pemotongan sinyal EKG menjadi sinyal per *beat* dilakukan dengan menggunakan titik R sebagai *pivolt*. Dengan menggunakan puncak gelombang pada segmen QRS, maka sinyal EKG akan dipisahkan

dengan mengambil 300 titik di *pivolt* tersebut. Secara detail peneliti mengambil 150 titik di sebelah kanan *pivolt* (R *peak*) dan 149 titik di sebelah kiri *pivolt* (R *peak*). Lebih jelasnya dapat peneliti lihat pada gambar 2.



Gambar 1. Sinyal EKG asli dan sinyal EKG hasil pengurangan *baseline* beserta isoelektriknya.



Gambar 2. Teknik pemotongan sinyal EKG menjadi tiap-tiap *beat*.

Filter data pelatihan terhadap data pencilan dilakukan karena dalam pengenalan *beat*, peneliti bertujuan untuk mendapatkan pola yang representatif yang bisa mewakili suatu pola kelas *beat* tertentu. Proses pelatihan dilakukan untuk mendapatkan pola yang representatif tersebut, sehingga jika sistem diberikan data pelatihan yang baik maka akan belajar dengan lebih baik daripada diberikan data yang kacau atau rusak. Data yang kacau atau rusak berupa data pencilan di mana dengan keberadaan data tersebut pola yang dihasilkan sistem pembelajaran akan menjadi buruk atau mengalami gangguan (*noisy*). Peneliti menggunakan jarak Mahalanobis untuk filter data pencilan atau data pengganggu.

Secara umum jarak Mahalanobis ($D_m(x)$) dari sekelompok data $x=(x_1, x_2, x_3, \dots, x_N)^T$

dengan rata-rata $\mu=(\mu_1, \mu_2, \mu_3, \dots, \mu_N)^T$ dan kovarian matriks S didefinisikan pada persamaan 1.

$$D_m(x) = \sqrt{(x - \mu)^T S^{-1} (x - \mu)} \quad (1)$$

dimana S adalah kovarian matriks yang didefinisikan sebagai berikut dalam persamaan 2.

$$\text{cov} = \frac{1}{n} \sum_{i=1}^m (x_i - \bar{x})(x_i - \bar{x})^t \quad (2)$$

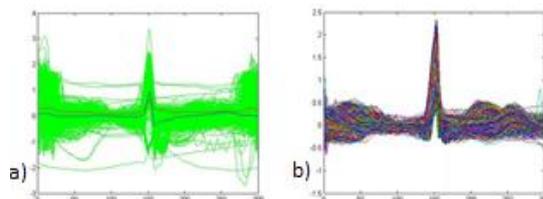
Jarak Mahalanobis dapat juga didefinisikan sebagai tingkat perbedaan (*dissimilarity measure*) antara dua random vektor x dan y yang memiliki distribusi yang sama dengan kovarian matriks S . Jarak Mahalanobis akan berguna jika kedua vektor memiliki korelasi, varian yang berbeda, distribusi data gaussian atau mendekati distribusi gaussian dan kovarian matriks dari kedua vektor tersebut merupakan matriks *non-singular*.

Prosedur untuk melakukan filter data dari *noise* menggunakan jarak Mahalanobis, pertamanya data akan dinormalisasi menggunakan *z-score* menggunakan persamaan 3.

$$z_i = \frac{x_i - \bar{x}}{\sigma}, \quad (3)$$

Dengan tata nama z_i adalah data yang telah dinormalisasi menggunakan *z-score*, x_i adalah data ke- i , adalah rata-rata data *train*, dan σ adalah standar deviasi data *train*. Setelah dinormalisasi menggunakan *zeros mean*, langkah selanjutnya data akan dicari matriks kovariannya. Peneliti dapat melakukan filter terhadap data menggunakan jarak Mahalanobis, dengan aturan jika jarak lebih kecil dibandingkan *threshold* peneliti akan memasukkan data tersebut menjadi data *train* dan jika jaraknya lebih besar dibandingkan dengan *threshold* maka peneliti akan menghapus data tersebut sebagai data *train* kemudian memasukkannya menjadi data *test*.

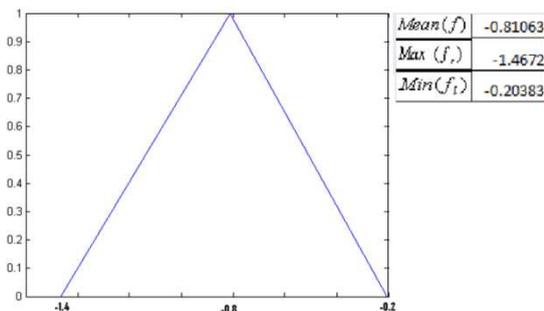
Perbedaan data yang mengandung *outlier* dan yang tidak mengandung *outlier* dapat dilihat pada gambar 3.



Gambar 3. (a) data *train* yang mengandung *outlier* (*noise*), (b) data yang bersih dari *outlier*.

Klasifikasi sistem EKG *beat* aritmia akan dibahas dengan menggunakan algoritma *Fuzzy Learning Vector Quantization* (FLVQ) dan *Fuzzy Wavelet Learning Vector Quantization* (FWLVQ) sebagai pengembangan dari FLVQ dengan menerapkan kombinasi antara FLVQ dengan *Fuzzy Wavelet Neural Network* (FWNN).

Fuzzy Learning Vector Quantization atau FLVQ ini, adalah sebuah LVQ dengan pemanfaatan teori *fuzzy* pada vektor masukan, proses pembelajaran, dan penentuan kategori vektor masukan. Penggunaan himpunan *fuzzy* ini pada vektor masukan bertujuan agar distribusi frekuensi data pengukuran dapat direpresentasikan, maka pada awal proses pembelajaran data hasil pengukuran fitur elektronik dinormalisasikan dalam bentuk vektor *fuzzy*. Bentuk vektor *fuzzy* yang sudah dinormalisasikan ini dinamakan bilangan *fuzzy* segitiga, untuk lebih jelasnya lihat gambar 4.



Gambar 4. Vektor *Fuzzy*.

Bilangan *fuzzy* segitiga ini merupakan pernyataan fungsi keanggotaan *fuzzy* untuk data hasil pengukuran, dengan nilai rata-rata (*mean*) mempunyai fungsi keanggotaan 1 sedangkan nilai terkecil (*min*) dan terbesar (*max*) mempunyai fungsi keanggotaan nol. *Fuzziness* atau karakteristik *fuzzy* menyatakan batas kelebaran dari fungsi keanggotaan *fuzzy* yang bernilai antara [0,1], semakin lebar nilai *Fuzziness* berarti semakin bervariasi data yang diolah.

Sistem jaringan *neural* buatan ini membutuhkan inialisasi awal untuk vektor perwakilan dan laju pembelajaran dalam memulai tahap pelatihan. Pada sistem ini, inialisasi dilakukan dengan mengambil salah satu vektor sebagai nilai vektor wakilnya. Seperti disebutkan pada bab sebelumnya, aturan pembelajaran pada FLVQ ini masih tetap berdasarkan pada mekanisme kompetisi yaitu hanya ada satu vektor perwakilan yang paling mirip dengan vektor masukan. Untuk menentukan vektor perwakilan yang paling mirip (*closest vector*) menggunakan nilai kemiripan atau similaritas yang diperoleh dengan prinsip operasi *fuzzy*.

Definisi nilai similaritas, andai kata x adalah vektor input dari n buah fitur dan w_i adalah vektor perwakilan untuk kategori i maka dapat dinyatakan bahwa:

$$x = (x_1, x_2, x_3, \dots, x_n)$$

dengan fungsi keanggotaan untuk vektor *fuzzy* x adalah:

$$h_x = (h_{x1}, h_{x2}, h_{x3}, \dots, h_{xn})$$

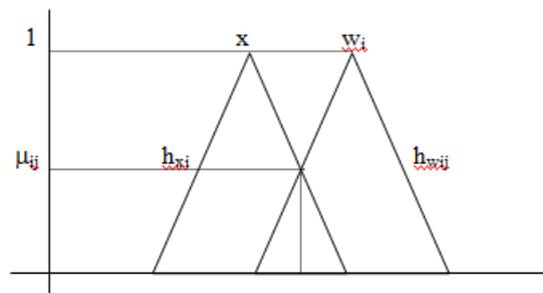
dan untuk vektor perwakilan i dapat dinyatakan:

$$w_i = (w_{i1}, w_{i2}, w_{i3}, \dots, w_{in})$$

dengan fungsi keanggotaan untuk w_i adalah:

$$h_{w_i} = (h_{w_i1}, h_{w_i2}, h_{w_i3}, \dots, h_{w_in})$$

Maka nilai similaritas (μ_{ij}) antara vektor perwakilan dengan vektor masukan dapat dijelaskan pada gambar 5.



Gambar 5. Nilai similaritas dari dua bilangan *fuzzy*.

Menghitung nilai similaritas, seperti yang terlihat pada gambar 5, nilai similaritas dari dua vektor *fuzzy* merupakan nilai maksimum dari irisan fungsi keanggotaan vektor *fuzzy* tersebut, dinyatakan dalam persamaan 4.

$$\mu_{ij} = \max(h_{xj} \wedge h_{wij}) \tag{4}$$

dengan i adalah jenis kategori keluaran dari jaringan FLVQ ini dan j adalah jenis input yang menjadi masukan FLVQ. Nilai similaritas ini dihitung untuk semua vektor perwakilan yang ada dengan vektor masukan.

Komputasi lapisan keluaran, setelah semua vektor perwakilan dihitung nilai similaritasnya dengan vektor *input*, maka pada tiap-tiap elemen di lapisan keluaran dicari nilai similaritas terkecilnya. Pencarian nilai similaritas minimum ini dapat dinyatakan dalam persamaan 5.

$$\mu_i = \min(\mu_{ij}) \tag{5}$$

dengan i adalah jenis kategori keluaran dari jaringan FLVQ ini dan j adalah jenis fitur yang menjadi masukan FLVQ.

Kemudian untuk menentukan vektor perwakilan pemenang dilakukan dengan cara mencari nilai similaritas terbesar yang ada pada tiap-tiap elemen lapisan keluaran tadi. Bila hasil keluaran mempunyai similaritas bernilai nol berarti menyatakan bahwa vektor *training* mempunyai jenis aroma yang tidak diketahui.

Aturan pembelajaran pada LVQ dilakukan dengan melakukan penggeseran posisi vektor perwakilan mendekati atau menjauhi vektor masukan untuk pelatihan. Sedangkan, pada FLVQ ada dua langkah untuk memperbaiki vektor perwakilan, yaitu melakukan penggeseran posisi vektor perwakilan dan melakukan perubahan kelebaran *fuzziness* dari vektor perwakilan. Ada tiga kasus di dalam proses pembelajaran pada jaringan neural buatan FLVQ berbasis similaritas. Pertama, bila lapisan keluaran menyatakan bahwa kategori vektor masukan x sama dengan vektor perwakilan pemenang w_c maka posisi vektor pemenang akan digeser mendekati vektor masukan kemudian *fuzziness* vektor pemenang diperlebar. Pergeseran dilakukan dengan menggunakan persamaan 6.

$$w_{cj}(t+1) = w_{cj}(t) + \alpha(t) \{ [1 - \mu_{cj}(t)] * \{x_j(t)\} - w_{cj}(t) \} \quad (6)$$

dengan tata nama:

j : 1, 2, 3, ..., n yaitu banyaknya fitur masukan

$w_{cj}(t+1)$: Posisi vektor perwakilan setelah penggeseran

$w_{cj}(t)$: posisi vektor perwakilan sebelum penggeseran

$\alpha(t)$: laju pembelajaran

$\mu_{cj}(t)$: nilai similaritas

$x_j(t)$: vektor masukan

Kedua, bila lapisan keluaran menyatakan bahwa kategori vektor masukan tidak sama dengan vektor perwakilan pemenang maka posisi vektor pemenang akan digeser menjauhi vektor masukan kemudian *fuzziness* vektor pemenang tersebut dipersempit. Pergeseran dilakukan dengan menggunakan persamaan 7.

$$w_{cj}(t+1) = w_{cj}(t) - \alpha(t) \{ [1 - \mu_{cj}(t)] * \{x_j(t)\} - w_{cj}(t) \} \quad (7)$$

dengan tata nama sebagai berikut:

j : 1, 2, 3, ..., n yaitu banyaknya fitur masukan

$w_{cj}(t+1)$: posisi vektor perwakilan setelah penggeseran

$w_{cj}(t)$: posisi vektor perwakilan sebelum penggeseran

$\alpha(t)$: laju pembelajaran

$\mu_{cj}(t)$: nilai similaritas

$x_j(t)$: vektor masukan

Ketiga, bila lapisan keluaran menyatakan bahwa similaritas vektor perwakilan dan vektor masukan adalah nol maka semua *fuzziness* vektor perwakilan diperlebar, menggunakan persamaan 8.

$$w_{ij}(t+1) = \delta(t) * w_{ij}(t) \quad (8)$$

dengan $\delta(t) = 1.1$.

Perubahan *Fuzziness*, seperti yang disebutkan sebelumnya setiap vektor *fuzzy* mempunyai nilai rata-rata, nilai minimum dan nilai maksimum. Perubahan *Fuzziness* seperti yang disebutkan pada bagian aturan pembelajaran di atas merupakan perubahan terhadap nilai minimum dan maksimum vektor *fuzzy*. Apabila x adalah sebuah vektor *fuzzy* maka x akan mempunyai tiga nilai. (1) l_x yaitu nilai minimum dari x . (2) c_x yaitu nilai rata-rata dari x . (3) r_x yaitu nilai maksimum dari x . Maka nilai l_x dan r_x setelah penggeseran vektor perwakilan pada aturan pembelajaran di atas adalah sebagai berikut:

Untuk kasus memperlebar *fuzziness* mempergunakan persamaan 9 dan 10.

$$l_x(t+1) = c_x(t+1) - \beta(c_x(t) - l_x(t)) \quad (9)$$

$$r_x(t+1) = c_x(t+1) + \beta(r_x(t) - c_x(t)) \quad (10)$$

Untuk kasus memperkecil *fuzziness* mempergunakan persamaan 11 dan 12.

$$l_x(t+1) = c_x(t+1) - \gamma(c_x(t) - l_x(t)) \quad (11)$$

$$r_x(t+1) = c_x(t+1) + \gamma(r_x(t) - c_x(t)) \quad (12)$$

dengan tata nama:

$l_x(t+1)$: nilai minimum x setelah terjadi penggeseran

$c_x(t+1)$: nilai rata-rata x setelah terjadi penggeseran

$r_x(t+1)$: nilai maksimum x setelah terjadi penggeseran

$l_x(t)$: nilai minimum x sebelum terjadi penggeseran

$c_x(t)$: nilai rata-rata x sebelum terjadi penggeseran

$r_x(t)$: nilai maksimum x sebelum terjadi penggeseran

β : konstanta pelebaran *fuzziness*, saat ini menggunakan nilai 0,05

γ : konstanta penyempitan *fuzziness*, saat ini menggunakan nilai 1,05

FLVQ dipilih sebagai algoritma untuk klasifikasi dalam sistem deteksi penyakit jantung aritmia karena FLVQ memiliki kelebihan dalam mengenali data yang *unknown* yaitu data yang kelas targetnya selain dari data yang telah dilatih oleh sistem. Sebagian besar algoritma klasifikasi, tidak mengatasi kemungkinan tersebut, sehingga semua data yang masuk dalam *test* akan dikenali sebagai bagian dari salah satu kelas yang ada walau sebenarnya data tersebut bukan merupakan bagian dari kelas target manapun dari target yang dilatihkan saat proses pembelajaran.

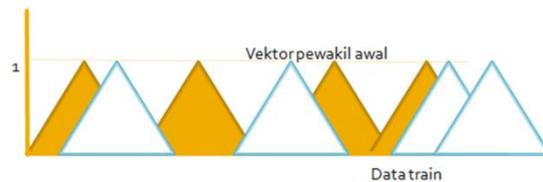
Fuzzy Wavelet Learning Vector Quantization (FWLVQ) merupakan modifikasi dari FLVQ yang dikombinasikan dengan FWNN. FWNN merupakan penggabungan antara konsep *Fuzzy Neural Network* (*Fuzzy-NN*) dengan *wavelet*. *Wavelet* dalam FWNN digunakan sebagai modifikasi dari *Fuzzy-NN* dalam proses *fuzzy* *rulanya*, dalam hal ini yang digunakan adalah model *fuzzy* Takagi Sugeno Kang. Jika pada *Fuzzy NN* dengan model Takagi Sugeno Kang yang sebelumnya, untuk *output* yang menggunakan konstanta atau fungsi linier maka dalam FWNN fungsi yang digunakan adalah fungsi *mother wavelet*. Untuk jelasnya dapat dilihat pada persamaan berikut:

$$\begin{aligned} & \text{if } x_1 \text{ is } A_1^{i_1} \text{ and } x_2 \text{ is } A_2^{i_2} \text{ and ...} \\ & \text{and } x_n \text{ is } A_n^{i_n} \text{ then } \psi_j(x) \end{aligned} \quad (13)$$

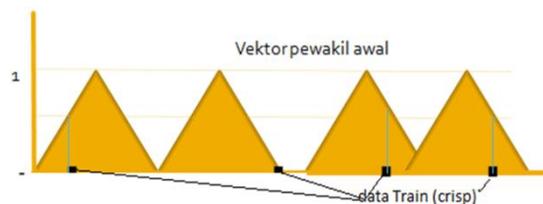
dengan tata nama, x adalah data input dengan jumlah fitur n , dan A adalah nilai fungsi keanggotaannya sedangkan $\psi_j(x)$ adalah fungsi *wavelet* dari x kelas ke j .

Modifikasi FLVQ peneliti lakukan karena FLVQ membutuhkan data input berupa data *fuzzy* atau data *crisp* yang bisa di-*fuzzy*-fikasi, sedangkan dalam EKG jika peneliti melakukan perekaman, maka sinyal yang dihasilkan adalah unik dan dalam satu *record* datangnya *beat* yang sama tidak dapat diketahui, misal pada saat perekaman 30 menit, terdapat 8025 *beat*, maka dari 8025 *beat* tersebut peneliti tidak dapat menentukan batasan interval suatu *beat* adalah satu jenis yang sama. Ada kemungkinan pada proses perekaman, *beat* 1 adalah normal dan *beat* 2 adalah LBBB kemudian normal lagi atau sebaliknya, maka akan sangat sulit jika peneliti menerapkan aturan FLVQ tanpa adanya penyesuaian. Untuk itu peneliti melakukan perubahan FLVQ terlebih dahulu sehingga memungkinkan untuk menggunakan data *crisp* sebagai data *input*.

Jadi dalam modifikasi FLVQ yang pertama sebelum masuk ke FWLVQ, peneliti melakukan perubahan dalam proses *fuzzy*-fikasi. *Fuzzy*-fikasi dalam modifikasi ini dilakukan dengan memasukkan data *crisp* dalam fungsi keanggotaan *fuzzy* yang telah dibangun dari data *train* yang ada dengan membentuk segitiga *fuzzy* dari vektor pewakilnya. Modifikasi yang dilakukan dapat dilihat pada gambar 6 dan gambar 7 untuk lebih jelasnya.



Gambar 6. *Fuzzy intersection* dari vektor referensi FLVQ dengan vektor masukan.



Gambar 7. *Intersection* dengan data *crisp* menggunakan modifikasi FLVQ.

Dalam penentuan kelas pemenang peneliti menghitung fungsi keanggotaan dari data input dengan menggunakan fungsi keanggotaan pada *fuzzy*. Jika peneliti menggunakan fungsi keanggotaan segitiga atau yang disebut dengan *Trimf* atau *triangle membership function*, maka peneliti menggunakan persamaan 14:

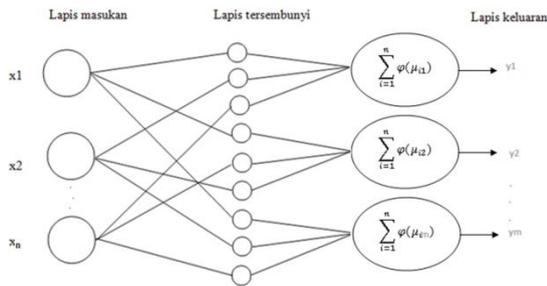
$$f(x;a,b,c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (14)$$

Dengan tata nama, x adalah data *input*, a adalah batas bawah segitiga *fuzzy* pada vektor perwakilan, b adalah nilai tengah atau rata-rata dari vektor perwakilan dan c adalah nilai *maximum* atau batas atas dari segitiga pada vektor perwakilan.

Kelebihan dari modifikasi selain untuk mengatasi data sekuensial, yaitu data yang datangnya berupa nilai *single* (*beat* yang berbeda-beda dalam *record* EKG) sehingga tidak mungkin untuk dilakukan pengelompokan untuk membentuk data *fuzzy*, modifikasi ini juga

memungkinkan untuk melakukan variasi fungsi keanggotaan. Jika dalam FLVQ sebelumnya fungsi keanggotaan hanya mampu untuk fungsi keanggotaan segitiga, maka dalam FLVQ yang telah dimodifikasi ini memungkinkan peneliti untuk menggunakan fungsi keanggotaan selain segitiga, misal gaussian, *bell function*, dan fungsi keanggotaan lainnya.

Peneliti mengadopsi sistem FWNN yang menggunakan model Takagi Sugeno Kang dalam proses *fuzzy*-nya. Untuk lebih jelasnya, arsitektur FWLVQ dapat dilihat pada gambar 8.

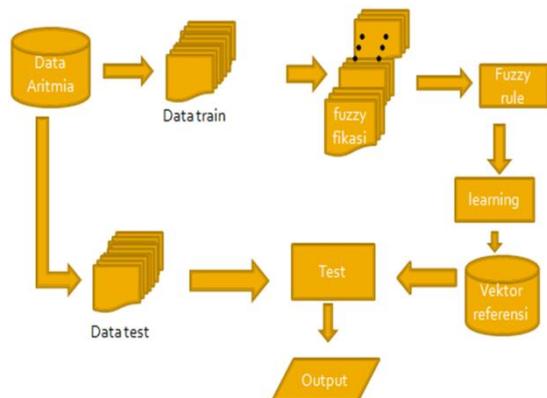


Gambar 8. Arsitektur FWLVQ.

Modifikasi FWLVQ hanya dilakukan pada penentuan *membership function* yaitu dengan menggunakan fungsi segitiga pada persamaan 13 dan pada saat penentuan *output* dengan menggunakan persamaan 14. Setelah didapatkan nilai *membership function* dari data input *crisp* maka akan dimasukkan dalam fungsi *mother wavelet* untuk menghitung nilai terdekatnya. Fungsi *mother wavelet* yang digunakan adalah fungsi *Mexican hat* yang dapat dilihat pada persamaan 15.

$$\psi(z) = \alpha(1 - z^2) * e^{-z^2} \quad (15)$$

Diagram alir proses dalam percobaan ini dapat dilihat pada gambar 9.



Gambar 9. Blok diagram sistem klasifikasi *beat* aritmia dengan FWLVQ.

3. Hasil dan Pembahasan

Dalam penelitian ini pengenalan pola *beat* aritmia dilakukan pada data MIT-BIH untuk enam kelas *type beat* aritmia yaitu *Left Bundle Branch Block Beat* (LBBB), *Right Bundle Branch block beat* (RBBB), *premature ventricular contraction* (PVC), *Fusion of ventricular and normal beat* (fVN), dan *normal beat* (NOR) serta terdapat satu kelas untuk jenis aritmia selain lima jenis *beat* tersebut. Untuk mencoba kemampuan FLVQ dalam mengenali *beat* aritmia beserta kemampuannya untuk mengenali *unknown category beat* aritmia, peneliti melakukan percobaan dengan menggunakan fitur 300 (belum dilakukan proses reduksi dimensi) dengan klaster *fuzzy*-fikasi sebesar 10 dan *learning rate* 0.002 serta variasi iterasi. Akurasi pengenalan aritmia dengan FVLQ modif I dapat dilihat pada Tabel I. Akurasi yang dihasilkan oleh FLVQ dalam percobaan ini dapat dilihat pada tabel II dan grafik pada gambar 10.

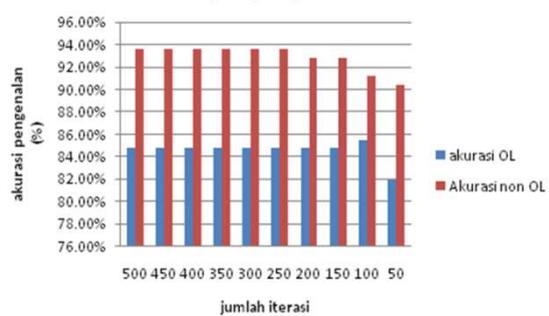
TABEL I

AKURASI PENGENALAN ARITMIA DENGAN FVLQ MODIF I				
Learning Rate	Jumlah Fitur	Jumlah Iterasi	Akurasi non OL	Akurasi OL
0,002	300	50	86,96%	78,66%
0,002	300	100	88,80%	80,25%

TABEL II

AKURASI FLVQ DALAM PENGENALAN BEAT ARITMIA			
Jumlah Fitur	Jumlah Iterasi	Akurasi OL	Akurasi Non OL
300	500	84,78%	93,60%
300	450	84,78%	93,60%
300	400	84,78%	93,60%
300	350	84,78%	93,60%
300	300	84,78%	93,60%
300	250	84,78%	93,60%
300	200	84,78%	92,80%
300	150	84,78%	92,80%
300	100	85,50%	91,20%
300	50	81,88%	90,40%

Grafik Akurasi (FLVQ)Pengenalan Beat Aritmia



Gambar 10. Grafik akurasi FLVQ dalam pengenalan *beat* aritmia.

Penurunan angka akurasi yang dihasilkan oleh FLVQ modif I menjadi salah satu sebab

untuk diterapkan proses modifikasi dengan kombinasi ke *wavelet*. Hasil percobaan yang peneliti lakukan untuk klasifikasi *beat* aritmia menggunakan FWLVQ dapat dilihat pada tabel III dan gambar 11.

TABEL III
TABEL AKURASI FWLVQ DENGAN VARIASI JUMLAH ITERASI

Learning Rate	Jumlah Fitur	Jumlah Iterasi	Akurasi OL	Akurasi Non OL
0,002	300	500	86,31%	89,60%
0,002	300	400	86,69%	90,00%
0,002	300	300	86,69%	90,00%
0,002	300	250	86,31%	89,60%
0,002	300	200	86,08%	89,20%
0,002	300	150	86,54%	89,60%
0,002	300	100	86,65%	89,80%
0,002	300	50	87,19%	90,20%



Gambar 11. Grafik akurasi FWVLQ dengan variasi jumlah iterasi.

Dari tabel 3 dan gambar 11 maka dapat dilihat bahwa dengan kombinasi *wavelet* akurasi pengenalan FWLVQ modif dapat meningkat dan sistem lebih mampu mengenali data *unknown* dengan baik. Percobaan tersebut dilakukan dengan data *unknown* yang merupakan pengabungan dari 4 kelas selain kelas yang di-*train*.

4. Kesimpulan

Beberapa kesimpulan dapat diambil dari penelitian ini. Pertama, modifikasi FWLVQ dapat meningkatkan kemampuan untuk mendeteksi adanya *unknown test* dengan akurasi rata-rata 86.5%. Kedua, dibandingkan dengan FLVQ terhadulu FWLVQ memiliki kelebihan untuk data yang sekuensial atau data yang dalam *inputnya* adalah tunggal, sehingga tidak memungkinkan untuk dilakukan perubahan menjadi data *fuzzy* jika dilakukan dengan teknik pengelompokan.

Ketiga, sistem ekstraksi *beat* dengan menggunakan teknik *cut off* sangat memungkinkan terjadinya kesalahan pengambilan *beat*, hal ini terlihat pada saat filter *outlier* data *train* sehingga memungkinkan terjadinya kesalahan juga dalam data *test*, yang hal ini dapat menyebabkan penurunan akurasi klasifikasi.

Pengembangan pada riset yang akan datang adalah mengembangkan FWLVQ menjadi sistem yang tersinergi dengan proses ekstraksi fitur sehingga memungkinkan sistem lebih efisien dan performa algoritma FWLVQ diharapkan lebih baik lagi. Proses ekstraksi *beat* juga akan dikembangkan dengan menggunakan teknik yang lebih analitis daripada sekedar *cut off* seperti dalam *paper* ini.

Referensi

- [1] I. Güler & E.D. Übeyli, "ECG Beat Classifier Designed by Combined Neural Network Model, Pattern Recognition," *Journal of the Pattern Recognition Society*, vol. 38, pp. 199-208, 2005.
- [2] T.H. Yeap, F. Johnson, & M. Rachniowski, "ECG Beat Classification by a Neural Network, Engineering in Medicine and Biology Society" *In Proceedings of the Twelfth Annual International Conference of the IEEE*, pp. 1457-1458, 1990.
- [3] Y. Ozbay & B. Karlik, "A recognition of EKG Arrythiemias Using Artificial Neural Networks, Engineering in Medicine and Biology Society" *In Proceedings of the 23rd Annual International Conference of the IEEE*, pp. 1680-1683, 2001.
- [4] A.M. Elsayad, "Classification of EKG Arrhythmia Using Learning Vector Quantization Neural Networks, Computer Engineering & Systems" *In ICCES 2009*, pp. 139-144, 2009.
- [5] L. Shyu, Y. Wu, & W. Hu, "Using Wavelet Transform and Fuzzy Neural Network for VPC Detection from the Holter ECG," *Biomedical Engineering, IEEE Transactions on*, vol. 51, pp.1269-1273, 2004.
- [6] R. Ceylan & Y. Özbay, "Comparison of FCM, PCA and WT Techniques for Classification EKG Arrhythmias using Artificial Neural Network," *Expert Systems with Applications: An International Journal*, vol. 33, pp. 286-95, 2007.
- [7] H. Zhang & L. Zhang, "EKG analysis based on PCA and Support Vector Machines" *In International Conference on Neural Networks and Brain ICNN&*, vol. 2, pp.743-747, 2005.
- [8] G. Karraz & G. Magenes, "Automatic Classification of Heartbeats Using Neural Network Classifier Based on a Bayesian Framework" *In Proceeding of the 28th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS)*, pp. 4016-4019, 2006.

- [9] B.Anuradha & V.C.V. Reddy, "Cardiac Arrhythmia Classification Using Fuzzy Classifiers," *Journal of Theoretical and Applied Information Technology*, vol. 1, pp. 353-359, 2008.
- [10] T.P. Exarchos, M.G. Tsipouras, C.P. Exarchos, C. Papaloukas, D.I. Fotiadis, & L.K. Michalis, "A Methodology for The Automated Creation of Fuzzy Expert Systems for Ischaemic and Arrhythmic Beat Classification Based on a Set of Rules Obtained by a Decision Tree," *Journal of Artificial Intelligence in Medicine*, vol. 40, pp. 187-200, 2007.
- [11] Y.- Yeh, W.Wang, & C.W. Chiou, "Heartbeat Case Determination Using Fuzzy Logic Method on ECG Signals," *International Journal of Fuzzy Systems*, vol. 11, pp. 250-261, 2009.
- [12] F. Melgani & Y. Bazi, "Classification of Electrocardiogram Signals with Support Vector Machines and Particle Swarm Optimization," *IEEE Transaction on Information Technology in Biomedicine*, vol.12, pp. 667-677, 2008.
- [13] A. Kampouraki, G. Manis, & C. Nikou, "Heartbeat Time Series Classification With Support Vector Machines," *IEEE Transactions on Information Technology in Biomedicine*, vol.13, pp.512-518, 2009.
- [14] J.A. Nasiri, M. Naghibzadeh, H.S. Yazdi, & B. Naghibzadeh, "ECG Arrhythmia Classification with Support Vector Machines and Genetic Algorithm" *Third UKSim European Symposium on Computer Modeling and Simulation*, pp.187-192, 2009.
- [15] R. Ghongade & A.A. Ghatol, "A Brief Performance Evaluation of ECG Feature Extraction Techniques for Artificial Neural Network Based Classification" *TENCON 2007 IEEE Region 10 Conference*, pp. 1-4, 2007.
- [16] Q. Zhao & L. Zhang, "ECG Feature Extraction and Classification Using Wavelet Transform and Support Vector Machines" *International Conference on Neural Networks and Brain*, pp. 1089-1092, 2005.
- [17] P.d. Chazal, M. O'Dwyer, & R.B. Reilly, "Automatic Classification of Heartbeats Using EKG Morphology and Heartbeat Interval Features," *IEEE Transactions on Biomedical Engineering*, vol. 51, pp. 1196-1206, 2004.
- [18] W. Jatmiko, T. Fukuda, F. Arai, & B. Kusumoputro, "Artificial Odor Discrimination System Using Multiple Quartz Resonator Sensor and Various Neural Networks for Recognizing Fragrance Mixtures," *IEEE Sensors Journal*, vol. 6, pp. 223-233, 2006.
- [19] I.M.A. Setiawan, E. Matul, Pambudi, & W. Jatmiko, "Heart Beat Classification Using Wavelet Feature" *International Conference on Advance Computer Science and Information System ICACSIS*, pp. 17-26, 2010.
- [20] W. Jatmiko, N.W. Pambudi, E. Matul, I.M.A. Setiawan, & P. Mursanto, "Heart Beat Classification Using Wavelet Feature Based on Neural Network," *Word Scientific and Engineering Academi and Society (WSEAS) Transaction on System*, vol.11, pp. 17-26, 2011.
- [21] S. Yilmaz & Y. Oysal, "Fuzzy Wavelet Neural Network Models for Prediction and Identification of Dynamical Systems," *IEEE Transactions on Neural Networks*, vol. 21, pp. 1599-1609, 2010.
- [22] C.-J. Lin, C. Chen, & C. Lee, "Classification and Medical Diagnosis Using Wavelet-Based Fuzzy Neural Networks," *International Journal of Innovative Computing Information and Control*, vol. 4, pp. 735-748, 2008.
- [23] G.B. Moody, MIT-BIH Arrhythmia Database Directory, Massachusetts Institute of Technology, <http://physionet.org/physiobank/database/html/mitdbdir/mitdbdir.htm>, 1997, retrieved December 10, 2010.
- [24] F. Badilini, A.J. Moss, & E.L. Titlebaum, "Cubic spline Baseline Estimation in Ambulatory ECG Recordings for the Measurement of ST-Segment Displacements" *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 584-585, 1991.