

## Deteksi Penyakit Jantung *Ventricular Tachyarrhythmia* dengan Metode *Principal Component Analysis* dan *Levenberg Marquardt Backpropagation* pada Sinyal Elektrokardiogram

### *Detection of Ventricular Tachyarrhythmia Disease with Principal Component Analysis Method and Levenberg Marquardt Backpropagation on Electrocardiogram Signals*

Astrima Manik<sup>1</sup>, Adiwijaya<sup>2</sup>, Dody Qori Utama<sup>3</sup>

<sup>1,2,3</sup>Prodi S1 Ilmu Komputasi, Fakultas Informatika, Universitas Telkom

<sup>1</sup>[astrimamanik@student.telkomuniversity.ac.id](mailto:astrimamanik@student.telkomuniversity.ac.id), <sup>2</sup>[adiwijaya@telkomuniversity.ac.id](mailto:adiwijaya@telkomuniversity.ac.id),

<sup>3</sup>[dodyqori@telkomuniversity.ac.id](mailto:dodyqori@telkomuniversity.ac.id)

#### Abstrak

*Ventricular Tachyarrhythmia* adalah salah satu jenis penyakit aritmia yang memiliki irama detak jantung menjadi lebih cepat sehingga terjadi ketidaknormalan pada bagian ventrikel jantung. Dalam dunia kesehatan, penyakit *ventricular tachyarrhythmia* dapat diketahui seseorang dari pemeriksaan suatu alat kedokteran yaitu elektrokardiogram (EKG). Secara umum, pendeteksian *ventricular tachyarrhythmia* juga dapat dilakukan dengan pengekstraksian ciri sinyal EKG serta dilakukan pengklasifikasian. Pada penelitian ini, penulis menggunakan metode median filter dalam hal *preprocessing*, teknik *Principal Component Analysis* (PCA) dalam hal ekstraksi ciri sinyal jantung dan *modified backpropagation* (MBP) yaitu *Levenberg Marquardt's* sebagai klasifikasi. Metode *Principal Component Analysis* (PCA) digunakan untuk mereduksi jumlah sampel agar dapat mengekstraksi gelombang QRS kompleks (ciri penyakit VT). Sedangkan algoritma *Levenberg Marquardt's* digunakan untuk mempercepat proses pelatihan. Berdasarkan penelitian yang telah dilakukan dengan menggunakan seluruh metoda diatas, didapatkan hasil akurasi yang terbaik diperoleh sebesar 93,06% saat menggunakan metoda PCA+MBP dengan parameter yang terbaik yaitu *principal component*=10, *hidden neuron*=5 dan nilai  $\mu=0.0016$  serta waktu pelatihan 1 detik.

**Kata Kunci :** *Elektrokardiogram, Levenberg Marquardt's Backpropagation, Median filter, Principal Component Analysis, dan Ventricular Tachyarrhythmia*

#### Abstract

*Ventricular Tachyarrhythmia* is one type of arrhythmia disease that has a heartbeat rhythm becomes faster resulting in abnormalities in the heart's ventricle. The detection of VT using electrocardiogram (ECG) signals is important for the prediction of a possible arrhythmia. This study focuses on the classification of VT heartbeats from ECG signals by using median filter method in preprocessing, *Principal Component Analysis* (PCA) technique in the characteristic extraction and *modified backpropagation* (MBP) as classification. Moreover, the performance effects of several dimension reduction approach tested with PCA. This research used machine learning method that is a neural network with *backpropagation* modification that is *Levenberg Marquardt* to speed up network training process. Based on the research that has been done using all the above method, obtained the best accuracy result that 93.06% when using PCA+MBP method with the best parameters that *principal component*=10, *hidden neuron*=5, and  $\mu$  value=0.0016 as well training time 1 seconds.

**Keywords :** *Elektrokardiogram, Levenberg Marquardt's Backpropagation, Median filter, Principal Component Analysis, and Ventricular Tachyarrhythmia*

#### 1. Pendahuluan

Jantung merupakan salah satu organ manusia yang memiliki peran fungsi paling penting yaitu memompa darah ke seluruh tubuh. Ketika jantung memompa darah ke seluruh tubuh, otot jantung berkontraksi dan menghasilkan detakan jantung. Detak jantung normal menunjukkan kondisi jantung yang dapat memompa darah secara optimal keseluruh tubuh. Sedangkan detak jantung yang tidak normal terdapat adanya gejala pada jantung yang dapat mengakibatkan kematian. Di Indonesia angka kematian yang disebabkan penyakit jantung mencapai 26 hingga 30 persen. Berdasarkan data yang dikemukakan World Heart Federation (WHF), penyakit jantung mencapai 29,1 persen atau sebanyak 17,1 juta pasien setiap tahunnya meninggal diseluruh dunia. Penyakit jantung yang menyebabkan kematian tersebut salah satunya adalah aritmia.

Aritmia adalah masalah pada jantung yang terjadi ketika organ tersebut berdetak terlalu cepat, terlalu lambat, atau tidak teratur. Detakan jantung dikelompokkan dalam tipe tachycardia dan bradycardia. Tipe aritmia juga dikelompokkan pada yaitu tipe atrial dan tipe ventricular. Tipe atrial saat ketidaknormalan pada bagian atrium. Sebaliknya, ventricular terjadi bila ketidaknormalan pada bagian ventrikel. Banyak jenis aritmia yang termasuk ke dalam tipe tersebut, namun pada penelitian ini hanya dibatasi pada penyakit *Ventricular Tachyarrhythmia* (VT) beserta Normal Sinus Rhytm (NSR).

Untuk mengurangi angka kematian yang disebabkan oleh penyakit jantung VT tersebut dapat dicegah dengan pemeriksaan dini melalui citra medis digital. Belakangan ini, citra medis digital dan catatan medis pasien banyak dilakukan kedokteran melalui jaringan komputer untuk digunakan dalam praktik pemeriksaan kesehatan seseorang [5]. Citra medis digital dapat diperoleh dengan beberapa cara seperti penelitian [6] menyediakan kompresi gambar digital dengan menggunakan kuantisasi perwarnaan graf yang diadopsi dari prinsip VQ. Salah satu citra medis digital yang digunakan dalam pemeriksaan sinyal jantung ini adalah elektrokardiogram (EKG). Dalam pengembangan EKG dibutuhkan suatu teknik klasifikasi yang baik untuk mendeteksi penyakit jantung agar menghasilkan prediksi yang tepat. Belakangan ini, banyak penelitian yang telah dilakukan untuk klasifikasi penyakit jantung pada sinyal EKG. Elif (2010) menggunakan pelatihan backpropagation neural network dengan algoritma Levenberg-Marquardt untuk klasifikasi sinyal EKG. Penelitian [1] klasifikasi aritmia menggunakan PCA sebagai fitur seleksi dan Elman Neural Network sebagai metode klasifikasi menghasilkan akurasi sebesar 95%.

Berdasarkan sumber penelitian diatas, penulis memilih untuk menggunakan metode PCA dalam pengestraksian ciri sinyal EKG dan pengklasifikasian menggunakan metode modifikasi backpropagation (MBP) pada neural network yaitu algoritma Levenberg-Marquardt karena PCA dapat mendeteksi ciri sinyal jantung dengan baik sedangkan algoritma Levenberg-Marquardt dapat mempercepat proses pelatihan saat dilakukan klasifikasi. Metode tersebut akan mengungkapkan kondisi sinyal EKG tergolong penyakit VT atau jantung normal.

## 2. Studi Literatur

Berbagai penelitian telah dilakukan oleh para ahli untuk klasifikasi penyakit jantung pada sinyal EKG. Zumray dan Tamer (2011) menyajikan sebuah hybrid neural network untuk klasifikasi sinyal EKG, dimana penulis menggunakan dua metode ekstraksi ciri yaitu fourier dan wavelet. Elif (2010) menggunakan pelatihan backpropagation neural network dengan algoritma Levenberg-Marquardt untuk klasifikasi sinyal EKG. Penelitian [1] klasifikasi aritmia menggunakan PCA sebagai fitur seleksi dan Elman Neural Network sebagai metode klasifikasi menghasilkan akurasi sebesar 95%. Untuk memperbaiki efisiensi komputasi, fitur reduksi menggunakan PCA guna untuk mengeliminasi signifikan yang rendah serta fitur redundansi [2]. Untuk mempercepat proses pelatihan dalam klasifikasi dengan menggunakan levenberg marquardt backpropagation [3]. Dari beberapa penelitian diatas, penulis mendeteksi penyakit VT dengan menggunakan PCA sebagai metode ekstraksi ciri dan modified backpropagation yaitu levenberg marquardt sebagai klasifikasinya.

## 3. Rancangan Sistem

### 3.1 Dataset Spesifikasi

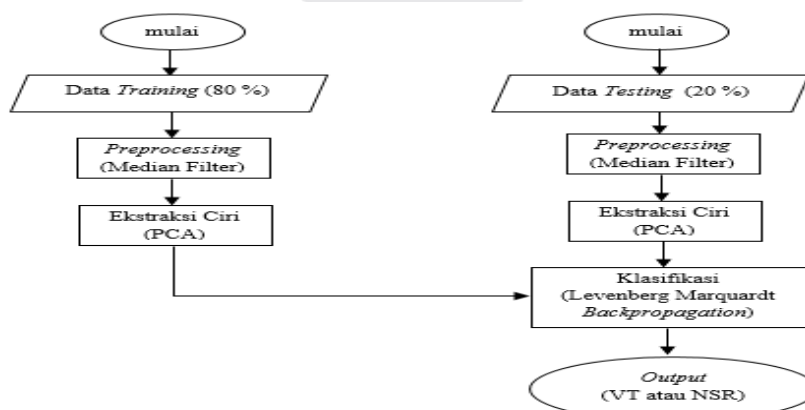
Penelitian ini menggunakan data masukan rekaman EKG yang diperoleh dari data *ready* dari sebuah web *Physionet* [4] yaitu data *Ventricular Tachyarrhythmia* (VT) dan data *Normal Sinus Rhythm* (NSR) dalam file ber-ekstensi .mat. Spesifik data masukan yang digunakan dapat dilihat pada Tabel 1.

**Tabel 1 Data Masukan**

	Jumlah Record	Jumlah Sampel
Data VT	34 records	@2500 sampel
Data NSR	18 records	@1280 sampel

### 3.2 Gambaran Umum Sistem

Pada penelitian ini, dilakukan suatu perancangan sistem yang dimulai dengan 3 tahap yaitu tahap pemrosesan awal (preprocessing), tahap ekstraksi ciri dan tahap klasifikasi. Diagram rancangan sistem dapat dilihat pada Gambar 1.



**Gambar 1** Gambaran Umum Sistem

Berdasarkan Gambar 1 secara umum dijelaskan bahwa tahap pertama yang dilakukan yaitu data VT masuk kedalam tahap *preprocessing* dengan menggunakan *median filter* dimana tujuan tahapan ini adalah untuk menghilangkan *noise* seperti *baseline wander*. Setelah data sinyal di-*preprocessing*, lalu data akan dilakukan ekstraksi ciri guna untuk mengambil ciri pola sinyal VT serta dilakukan reduksi dimensi pada jumlah sampel sinyal tersebut. Metoda yang digunakan pada tahapan ekstraksi ciri adalah PCA yang nantinya akan menghasilkan variabel baru (*principal component*) guna untuk menjadi data inputan pada klasifikasi menggunakan modifikasi *backpropagation* yaitu algoritma *levenberg marquardt*.

### 3.3 Skenario Pengujian

Penelitian ini menggunakan dua skenario pengujian yaitu saat menggunakan PCA+MBP dan Tanpa PCA+ MBP. Tujuan dilakukan skenario pengujian ini adalah untuk melihat perbandingan hasil performansi terbaik yang didapat saat data dilakukan reduksi dengan yang tidak direduksi. Distribusi data yang digunakan yaitu 80% data latih dan 20% data uji. Pada skenario pengujian ini dilakukan perubahan parameter untuk mencari parameter terbaik pada sistem yaitu *principal component*, *hidden neuron*, dan nilai  $\mu$ . Berikut skenario pengujian pada sistem:

1. Skenario PCA+ MBP
 

Pada skenario ini akan dilakukan 3 pengujian guna mencari parameter terbaik sebagai berikut:

  - a. Untuk mengetahui *principal component* yang paling tepat digunakan pada proses ekstraksi ciri, dilakukan pengujian terhadap berbagai jumlah sampel yang akan direduksi sebanyak *principal component*=10, 20, 30, 40 dan 50. Pada pengujian ini menggunakan jumlah *hidden neuron*=5 dan nilai  $\mu$ =0.0016
  - b. Untuk mengetahui jumlah *hidden neuron* yang paling tepat digunakan pada tahapan klasifikasi, maka dilakukan pengujian dengan jumlah *hidden neuron*=3, 4, dan 5. Pada pengujian ini menggunakan *principal component* yang terbaik berdasarkan pengujian pertama dan nilai  $\mu$ =0.0016.
  - c. Untuk mengetahui nilai  $\mu$  yang paling tepat digunakan pada tahapan klasifikasi, maka dilakukan pengujian dengan nilai  $\mu$ =0.0010, 0.0012, 0.0014, dan 0.0016. Pada pengujian ini menggunakan *principal component* yang terbaik berdasarkan pengujian pertama dan *hidden neuron* terbaik berdasarkan pengujian kedua.
2. Skenario Tanpa PCA+ MBP
 

Pada skenario ini akan dilakukan 2 pengujian lagi guna mencari parameter terbaik sebagai berikut:

  - a. Untuk mengetahui jumlah *hidden neuron* yang paling tepat digunakan pada tahapan klasifikasi, maka dilakukan pengujian dengan jumlah *hidden neuron*=3, 4, dan 5. Pada pengujian ini menggunakan nilai  $\mu$ =0.0016
  - b. Untuk mengetahui nilai  $\mu$  yang paling tepat digunakan pada tahapan klasifikasi, maka dilakukan pengujian dengan nilai  $\mu$ =0.0010, 0.0012, 0.0014, dan 0.0016. Pada pengujian ini menggunakan *hidden neuron* terbaik berdasarkan pengujian pertama.

## 4. Hasil Pengujian dan Analisis

### 4.1 Hasil skenario PCA+ MBP

Dalam skenario ini terdapat 3 parameter yang akan diubah dengan tujuan mencari parameter yang terbaik dalam pengujiannya, yaitu saat *principal component* (10, 20, 30, 40, dan 50), *hidden neuron* (3, 4, dan 5) serta nilai  $\mu$  (0.0010, 0.0012, 0.0014, dan 0.0016). Perubahan parameter ini akan dilakukan 3 pengujian lagi dengan hasil yang dapat dilihat pada Tabel 2.

**Tabel 2** Hasil Pengujian Pertama dengan Mencari *Principal Component* Terbaik

<i>Principal Component</i>	<i>Hidden neuron</i>	Nilai $\mu$	Akurasi Pengujian
10	5	0,0016	93,06%
20	5	0,0016	76,39%
30	5	0,0016	72,22%
40	5	0,0016	77,78%
50	5	0,0016	73,61%

Berdasarkan Tabel 2 dapat diketahui bahwa jumlah *principal component* akan mempengaruhi akurasi pengujian. Semakin sedikit jumlah *principal component* yang digunakan, maka akan menghasilkan akurasi pengujian terbaik karena dapat mereduksi jumlah sampel dengan sangat baik terbukti dengan dihasilkan nilai eigen yang tinggi. Semakin tinggi nilai eigen yang didapat maka semakin tinggi juga variansi data yang terdapat pada *principal component*. Semakin besar variansi setiap *principal component* berarti semakin penting keberadaan *principal component* tersebut. Hal ini terbukti saat jumlah *principal component* yang sedikit yaitu 10 menghasilkan akurasi terbaik sebesar 93.06%. Karena didapat *principal component* terbaik berjumlah 10, maka *principal component*=10 akan digunakan pada pengujian kedua.

Pengujian kedua yaitu menentukan *hidden neuron* yang terbaik dengan merubah nilai *hidden neuron* (3,4, dan 5) dengan nilai  $\mu$  tetap yaitu 0,0016 dan *principal component*=10 berdasarkan hasil pengujian pertama. Hasil pengujian kedua akan ditunjukkan pada Tabel 3.

**Tabel 3** Hasil Pengujian Kedua dengan Mencari *Hidden neuron* Terbaik

<i>Hidden neuron</i>	Nilai $\mu$	Akurasi Pengujian
3	0,0016	81,94%
4	0,0016	90,28%
5	0,0016	93,06%

Berdasarkan Tabel 3 dapat dilihat bahwa banyaknya jumlah *hidden neuron* yang digunakan akan mempengaruhi hasil akurasi pengujian. Semakin besar jumlah *hidden neuron* yang digunakan maka semakin besar hasil akurasi pengujian yang didapatkan. Hal ini karena semakin banyak jumlah *neuron* yang digunakan dalam sistem, maka tahap pembelajaran akan semakin panjang sehingga menghasilkan *network* yang dapat memetakan input ke target dengan tepat. Pada pengujian ini dihasilkan akurasi pengujian yang terbaik yaitu 93,06% saat *hidden neuron*=5. Karena didapatkan akurasi terbaik saat *hidden neuron*=5, maka *hidden neuron*= 5 akan digunakan pada pengujian ketiga yaitu nilai  $\mu$  yang terbaik dengan merubah nilai  $\mu$  (0.0010, 0.0012, 0.0014, dan 0.0016) dan nilai *principal component* tetap yaitu 10 pada hasil pengujian pertama serta jumlah *hidden neuron*=5 pada hasil pengujian kedua. Hasil pengujian ketiga akan ditunjukkan pada Tabel 4.

**Tabel 4** Hasil Pengujian Ketiga dengan Mencari Nilai  $\mu$  Terbaik

Nilai $\mu$	Akurasi Pengujian
0,001	88,89%
0,0012	86,11%
0,0014	80,56%
0,0016	93,06%

Berdasarkan Tabel 4 dapat diketahui bahwa penggunaan nilai  $\mu$  yang berbeda akan menghasilkan akurasi pengujian yang berbeda juga. Pada pengujian ini didapatkan semakin besar nilai  $\mu$  maka akan menghasilkan akurasi yang tinggi. Akurasi terbaik yang diperoleh pada pengujian ini yaitu sebesar 93,06% saat menggunakan nilai  $\mu$ =0.0016. Akurasi ini diperoleh karena penggunaan nilai  $\mu$  yang semakin besar dapat mempercepat laju pembelajaran sebab adanya lompatan yang semakin besar ketika melakukan perubahan bobot (*updating weight*). Setelah dilakukan 3 pengujian pada perubahan parameter tersebut, didapatkan hasil akurasi skenario menggunakan PCA+MBP beserta parameter terbaiknya dapat dilihat pada Tabel 5.

**Tabel 5** Hasil Akurasi Skenario PCA+MBP

	<i>Principal Component</i>	<i>Hidden neuron</i>	Nilai $\mu$	Akurasi Pengujian
PCA + MBP	10	5	0,0016	93,06%

Berdasarkan Tabel 5, hasil akurasi pengujian yang didapat pada skenario pengujian menggunakan PCA+MBP yaitu 93,06% dengan parameter terbaik yang digunakan yaitu *principal component*=10, *hidden neuron*=5, dan nilai  $\mu$ =0.0016.

#### 4.2 Hasil Skenario Tanpa PCA+MBP

Dalam skenario ini terdapat 2 parameter yang akan diubah dengan tujuan mencari parameter yang terbaik dalam pengujiannya, yaitu saat *hidden neuron* (3, 4, dan 5) serta nilai  $\mu$  (0.0010, 0.0012, 0.0014, dan 0.0016). Perubahan parameter ini akan melakukan 3 pengujian dengan hasil yang dapat dilihat pada Tabel 6.

**Tabel 6** Hasil Pengujian Pertama dengan Mencari *Hidden neuron* Terbaik

<i>Hidden neuron</i>	Nilai $\mu$	Akurasi Pengujian
3	0,0016	87,00%
4	0,0016	87,50%
5	0,0016	80,56%

Berdasarkan Tabel 6 dapat dilihat bahwa banyaknya jumlah *hidden neuron* yang digunakan pada *backpropagation* akan mempengaruhi hasil akurasi pengujian. Semakin besar jumlah *hidden neuron* yang digunakan maka semakin besar hasil akurasi pengujian yang didapatkan. Pada tahapan pengujian ini dihasilkan akurasi pengujian yang terbaik yaitu sebesar 87.50% saat *hidden neuron*=4. Oleh karena itu, *hidden neuron* yang paling tepat untuk digunakan pada pengujian ini adalah berjumlah 4. Pada dasarnya semakin banyak jumlah *neuron* yang digunakan dalam sistem, maka tahap pembelajaran akan semakin panjang sehingga menghasilkan *network* yang dapat memetakan input ke target dengan tepat. Karena didapatkan akurasi terbaik sebesar 87.50% saat menggunakan *hidden neuron*=4, maka *hidden neuron*=4 akan digunakan pada pengujian kedua. Pengujian kedua yaitu menentukan nilai  $\mu$  yang terbaik dengan merubah nilai  $\mu$  (0.0010, 0.0012, 0.0014, dan 0.0016). Hasil pengujian kedua akan ditunjukkan pada Tabel 7.

**Tabel 7** Hasil Pengujian Kedua dengan Mencari Nilai  $\mu$  Terbaik

Nilai $\mu$	Akurasi Pengujian
0,001	84,72%
0,0012	84,72%
0,0014	86,11%
0,0016	87,50%

Berdasarkan Tabel 7 dapat diketahui bahwa penggunaan nilai  $\mu$  yang berbeda akan menghasilkan akurasi pengujian yang berbeda juga. Pada pengujian ini didapatkan semakin besar nilai  $\mu$  maka akan menghasilkan akurasi yang tinggi. Akurasi terbaik yang diperoleh pada pengujian ini yaitu sebesar 87.50% saat menggunakan nilai  $\mu$ =0.0016. Pada dasarnya penggunaan nilai  $\mu$  yang semakin besar dapat mempercepat laju pembelajaran. Hal itu terjadi karena adanya lompatan yang semakin besar ketika melakukan perubahan bobot (*updating weight*).

Setelah dilakukan 2 pengujian pada perubahan parameter tersebut, didapatkan hasil akurasi skenario menggunakan Tanpa PCA+MBP beserta parameter terbaiknya dapat dilihat pada Tabel 8.

**Tabel 8** Hasil Akurasi Skenario Tanpa PCA+MBP

	<i>Hidden neuron</i>	Nilai $\mu$	Akurasi Pengujian
Tanpa PCA + MBP	4	0,0016	87,50%

Berdasarkan Tabel 8, hasil akurasi pengujian yang didapat pada skenario pengujian menggunakan Tanpa PCA+MBP yaitu 87.50% dengan parameter terbaik yang digunakan yaitu *hidden neuron*=4, dan nilai  $\mu$ =0.0016.

#### 4.3 Analisa Hasil Perbandingan Akurasi Skenario Pengujian

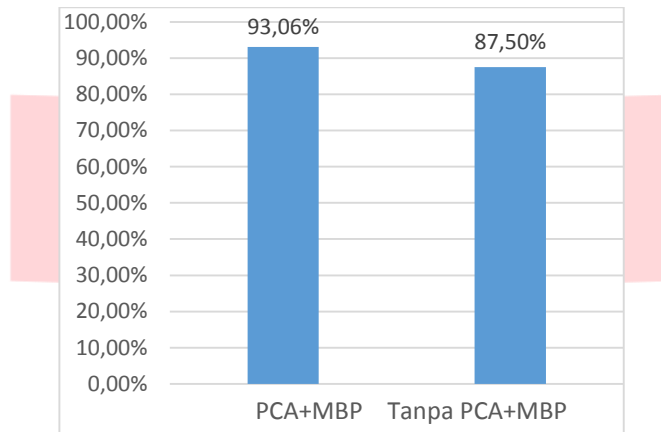
Setelah dilakukan skenario pengujian terhadap parameter yang diubah (*principal component*, *hidden neuron*, dan nilai  $\mu$ ) maka dihasilkan akurasi yang berbeda. Pada skenario yang pertama yaitu saat menggunakan PCA+MBP memperoleh akurasi terbaik sebesar 93,06% dengan parameter yang digunakan yaitu *principal component*=10, *hidden neuron*=5, dan nilai  $\mu$ =0.0016. Sedangkan pada skenario kedua yaitu saat menggunakan Tanpa PCA+MBP memperoleh akurasi terbaik sebesar 87.50% dengan parameter yang digunakan yaitu *hidden neuron*=4, dan nilai  $\mu$ =0.0016. Berdasarkan hasil akurasi yang diperoleh dari dua skenario tersebut, dapat disimpulkan bahwa skenario PCA+MBP yang terpilih menjadi skenario terbaik untuk digunakan pada penelitian ini. Hal ini dikarenakan akurasi yang didapatkan pada skenario PCA+MBP memperoleh akurasi tertinggi dibandingkan skenario Tanpa PCA+MBP yaitu sebesar 93,06% dengan parameter *principal component*=10, *hidden neuron*=5, dan nilai  $\mu$ =0.0016. Akurasi tersebut didapatkan karena jumlah sampel yang direduksi menjadi sangat kecil yaitu 10, jumlah *hidden neuron* yang semakin banyak yaitu 5, dan nilai  $\mu$  yang semakin besar yaitu 0.0016. Semakin sedikit jumlah *principal component* yang digunakan, maka akan menghasilkan nilai eigen yang semakin besar. Hal ini membuat keberadaan *principal component* menjadi sangat penting. Sehingga jumlah *principal component* yang semakin sedikit menghasilkan akurasi yang tinggi. Semakin banyak jumlah *hidden neuron* maka akan memperbagus hasil akurasi yang didapatkan. Hal itu terjadi karena pada dasarnya semakin banyak jumlah *neuron* yang digunakan dalam sistem, maka tahap pembelajaran akan semakin panjang sehingga menghasilkan *network* yang dapat memetakan input ke target dengan tepat. Semakin besar nilai  $\mu$  yang digunakan maka hasil akurasi pengujian pun akan semakin baik karena pada dasarnya penggunaan nilai  $\mu$  yang semakin besar dapat mempercepat laju pembelajaran sebab adanya lompatan yang semakin besar saat melakukan perubahan bobot (*updating weight*). Hasil perbandingan akurasi pada skenario pengujian dapat dilihat pada Tabel 9



**Tabel 9** Hasil Perbandingan Persentase Akurasi Skenario Pengujian

	Akurasi Pengujian	Training Time
PCA + MBP	93,06%	0:00:01
Tanpa PCA + MBP	87,50%	0:00:01

Berdasarkan Tabel 9 dapat dilihat bahwa skenario pengujian terbaik didapatkan saat menggunakan PCA+MBP dengan hasil akurasi sebesar 93,06%. Hal ini membuat metode PCA+MBP sangat baik digunakan pada penelitian ini. Terlebih waktu pelatihan yang dihasilkan sangat cepat yaitu 1 detik disetiap pengujianya. Hal ini dikarenakan adanya algoritma levenberg marquardt yang dapat mempercepat proses pelatihan pada jaringan ANN. Grafik perubahan persentase akurasi pengujian pada dua skenario tersebut dapat dilihat pada Gambar 2.



Gambar 2 Grafik Hasil Persentase Akurasi Pada Dua Skenario

## 5. Kesimpulan

Implementasi PCA + MBP yang dimodifikasi dalam ekstraksi ciri dan proses klasifikasi dapat memberikan akurasi yang tinggi pada sistem identifikasi penyakit jantung *ventricular tachyarrhythmia* dengan mendapatkan persentase akurasi sebesar 93,06% dengan waktu pelatihan 1 detik. Persentase akurasi diperoleh dari parameter terbaik yaitu *principal component*=10, *hidden neuron*=5 dan nilai  $\mu=0,0016$  dengan menggunakan data *training* 80% dan data *testing* 20%. Hal ini didapat karena metode PCA cukup baik untuk mengurangi dan mendeteksi gelombang QRS dan dapat mengklasifikasikan data dengan benar yang menggunakan modifikasi *backpropagation* yaitu algoritma *Levenberg Marquardt*.

## DAFTAR PUSTAKA

- [1] F.N. Mohamad, M.S.A Megat Ali, A. H. Jahidin, M.F. Saaid, and M.Z.H. Noor, "Principal Component Analysis and Arrhythmia Recognition Using Elman Neural Network", IEEE Control and System Graduate Research Colloquium, Aug 2013
- [2] D.Ge,L.Sum, J.Zhous, and Y.Shaos, "Discrimination of myocardial infarction stages by subjective feature extraction", Comput Meth. Prog. Blomed., vol.85, no.3, pp.270-279, Sep 2009
- [3] M.T.Hagan and M.Henhaj, "Training feedforward networks with the Marquardt algorithm,"IEEE Trans. Neural Networks, vol.5 pp. 989-93, 1994
- [4] <https://www.physionet.org/cgi-bin/atm/ATM>
- [5] Adiwijaya,Faoziyah, P.N., Permana, F.P., Wirayuda, T.A.B. and Wisesty, U.N.,2013. Tamper detection and recovery of medical image watermarking using modified LSB and Huffman compression. In informatics and Applications (ICIA), 2013 Second Internasional Conference on (pp.129-132). IEEE
- [6] Adiwijaya, Maharani, M., Dewi, B.K., Yulianto, F.A. and Purnama, B., 2013. Digital image compression using graph coloring quantization based on wavelet-SVD. In Journal

[6]

