

PERBANDINGAN ALGORITMA LEVENBERG-MARQUARDT DENGAN METODA BACKPROPAGATION PADA PROSES LEARNING JARINGAN SARAF TIRUAN UNTUK PENGENALAN POLA SINYAL ELEKTROKARDIOGRAF

Rahmat^{1,2)}, Rachmad Setiawan¹⁾, Mauridhi Hery Purnomo¹⁾

¹⁾Jurusan Teknik Elektro ITS, Surabaya Indonesia 6011

²⁾Politeknik Negeri Padang, Kampus UNAND Limau Manis Padang, Indonesia

E-mail: rahmat_agt@yahoo.com, rachmat@ee.its.ac.id, hery@ee.its.ac.id

ABSTRAKSI

Pengenalan pola EKG (Elektrokardiograf) merupakan suatu proses yang penting dalam menganalisa keadaan jantung pasien. Makalah ini menjelaskan tentang sebuah system pengenalan pola sinyal EKG menggunakan multi layer perseptron dan dilatih dengan algoritma Levenberg-Marquardt (LM). Algoritma (LM) merupakan pengembangan algoritma Backpropagation (BP) standar. Pada algoritma BP standar proses update bobot dan bias menggunakan negative gradient descent secara langsung sedangkan pada algoritma Levenberg-Marquardt menggunakan pendekatan matrik Hessian.

Pada penelitian ini dilakukan pengenalan terhadap lima jenis kelainan sinyal EKG yang berasal dari generator sinyal EKG secara on-line. Pra-proses dimulai dengan mengurangi noise yang menyertai sinyal EKG dengan teknik downsampling Haar wavelet, kemudian diambil spektrum frekuensi hasil downsampling ini untuk masukan Jaringan Saraf Tiruan.

Hasil learning jaringan dengan konfigurasi 100-15-5 dan error limit 0.0001 dibutuhkan 35 iterasi untuk mencapai konvergen pada LM, sedangkan dengan BP dibutuhkan 480 iterasi. Pengujian data learning dengan LM menghasilkan error terkecil 1×10^{-6} dan error terbesar terbesar 1×10^{-4} , untuk metoda BP error terkecil dicapai 1×10^{-4} dan error terbesar 1×10^{-3} .

Pengujian dengan data uji dari generator yang sama untuk 100 kali pengujian semua pola yang diuji dapat dikenali 100%.

Kata Kunci: Levenberg-Marquardt, Backpropagation, Jaringan Saraf Tiruan, Elektrokardiograf

1. Pendahuluan

Elektrokardiografi (EKG) merupakan gambaran sinyal potensial jantung yang diperoleh dengan cara menempatkan beberapa elektroda pada tubuh pasien. Penggunaan sinyal EKG sudah sangat umum di dunia kedokteran yaitu sebagai alat bantu untuk mendiagnosis kelainan pada jantung. Pola EKG dari kondisi jantung umumnya memiliki pola yang khusus, tetapi untuk membedakan apakah jantung dalam keadaan sehat atau terdapat suatu kelainan fungsional pada jantung diperlukan keahlian dan pengalaman melakukan klasifikasi dari pola-pola EKG yang sudah ada.

Teknik pengenalan pola EKG ini masih merupakan suatu topik yang menarik, dengan mempergunakan suatu sistem intelijensi buatan yang prinsipnya meniru kemampuan dari dokter untuk mengenali pola-pola EKG tersebut. Proses pengenalan diserahkan pada jaringan saraf tiruan (JST), dilakukan pengenalan beberapa pola sinyal jantung tanpa adanya tambahan informasi medis, maksudnya proses klasifikasi sinyal EKG benar-benar dilakukan oleh sistem intelijensia buatan tanpa adanya tambahan informasi dari luar.

1.1 Supervised Learning

Tujuan pembelajaran *supervise learning* adalah untuk menentukan nilai-nilai bobot koneksi didalam jaringan sehingga jaringan dapat melakukan

pemetaan (*mapping*) dari input ke output sesuai dengan yang diinginkan. Pemetaan ini ditentukan melalui satu set pola uji atau data pelatihan (*training data set*).

Setiap pasangan pola p terdiri dari vektor input x_{in} dan vektor target t_k . Setelah selesai pelatiha jika diberikan masukan x_{in} seharusnya jaringan menghasilkan nilai ouput t_k . Besarnya perbedaan antara nilai vektor target dengan ouput aktual diukur dengan *error*.

$$sse = \sum_{k=1}^p \frac{1}{2} (t_k - y_k)^2 \quad (1)$$

dimana k adalah banyaknya unit pada output layer. Tujuan dari training pada dasarnya adalah sama dengan mencari suatu nilai minimum global e

1.2 Algoritma Levenberg-Marquardt

Algoritma Levenberg-marquardt merupakan pengem merupakan pengembangan algoritma *backpropagation* standar. Pada algoritma *backpropagation*, proses *update* bobot dan bias menggunakan *negative gradient descent* secara langsung sedangkan..Algoritma Levenberg-Marquardt menggunakan pendekatan matrik Hessian (H) yang dapat dihitung dengan,

$$H = J^T e \quad (2)$$

sedangkan gradient dapat dihitung dengan,

$$g = J^T J \quad (3)$$

Dalam hal ini J merupakan sebuah matrik jacobian yang berisikan turunan pertama dari error jaringan terhadap bobot dan bias jaringan. Perubahan pembobot dapat dihitung dengan,

$$\Delta X = [J^T J + \mu I]^{-1} J^T e \quad (4)$$

sehingga perbaikan pembobot dapat ditentukan dengan

$$X = X + \Delta X \quad (5)$$

$$X = \Delta X + [J^T J + \mu I]^{-1} J^T e \quad (6)$$

$$\begin{bmatrix} \frac{\partial e_{11}(x)}{\partial x_1} & \frac{\partial e_{11}(x)}{\partial x_2} & \frac{\partial e_{11}(x)}{\partial x_3} & \dots & \frac{\partial e_{11}(x)}{\partial x_n} \\ \dots & \dots & \dots & \dots & \dots \\ \frac{\partial e_{k1}(x)}{\partial x_1} & \frac{\partial e_{k1}(x)}{\partial x_2} & \frac{\partial e_{k1}(x)}{\partial x_3} & \dots & \frac{\partial e_{k1}(x)}{\partial x_n} \\ \frac{\partial e_{12}(x)}{\partial x_1} & \frac{\partial e_{12}(x)}{\partial x_2} & \frac{\partial e_{12}(x)}{\partial x_3} & \dots & \frac{\partial e_{12}(x)}{\partial x_n} \\ \dots & \dots & \dots & \dots & \dots \\ \frac{\partial e_{k2}(x)}{\partial x_1} & \frac{\partial e_{k2}(x)}{\partial x_2} & \frac{\partial e_{k2}(x)}{\partial x_3} & \dots & \frac{\partial e_{k2}(x)}{\partial x_n} \\ \dots & \dots & \dots & \dots & \dots \\ \frac{\partial e_{kp}(x)}{\partial x_1} & \frac{\partial e_{kp}(x)}{\partial x_2} & \frac{\partial e_{kp}(x)}{\partial x_3} & \dots & \frac{\partial e_{kp}(x)}{\partial x_n} \end{bmatrix} \quad (7)$$

X = fungsi bobot-bobot jaringan dan bias

$$X = [v_{11}, v_{12}, \dots, v_{ij}; v_{01}, v_{02}, \dots, v_{0j}; w_{11}, w_{12}, \dots, w_{jk}; w_{01}, w_{02}, \dots, w_{0k}]$$

e adalah vector yang menyatakan semua error pada output jaringan

$$e = [t_1 - y_1, t_2 - y_2, \dots, t_p - y_p]^T$$

μ = konstanta learning

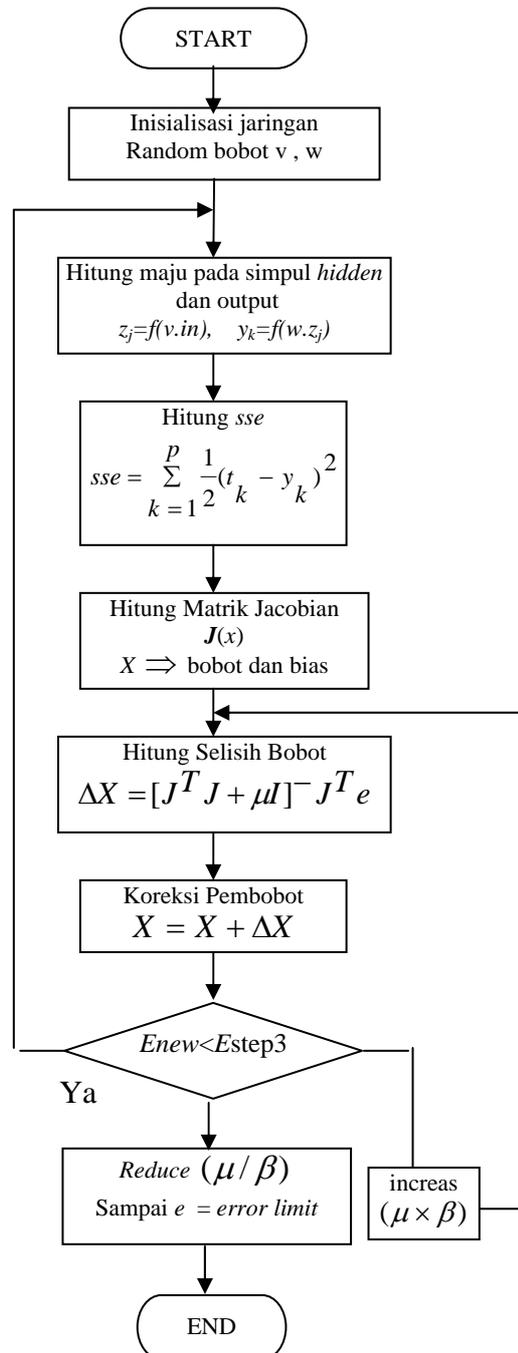
I = matrik identitas

2. Cara Penelitian

Data yang digunakan dalam penelitian ini terdiri dari lima macam jenis aritma (Kelainan) sinyal EKG yang bersal dari generator EKG. Sinyal EKG secara *rielttime disampling* dengan menggunakan peralatan akuisisi sebanyak 1024 data. Jumlah data tersebut dihasilkan lebih kurang 3 gelombang sinyal EKG.

Dilakukan proses pengolahan sinyal yaitu dengan teknik *downsampling* menggunakan transformasi Haar *wavelet*. Pada proses ini terjadi pemisahan sinyal frekuensi tinggi yang dapat dianggap sebagai *noise* (dalam transformasi wavelet dinamakan koefisien detail (cD) dan frekuensi rendah (dalam transformasi *wavelet* dinamakan koefisien aproksimasi (cA)). Satu kali proses *downsampling* menghasilkan sinyal setengahnya, pada penelitian

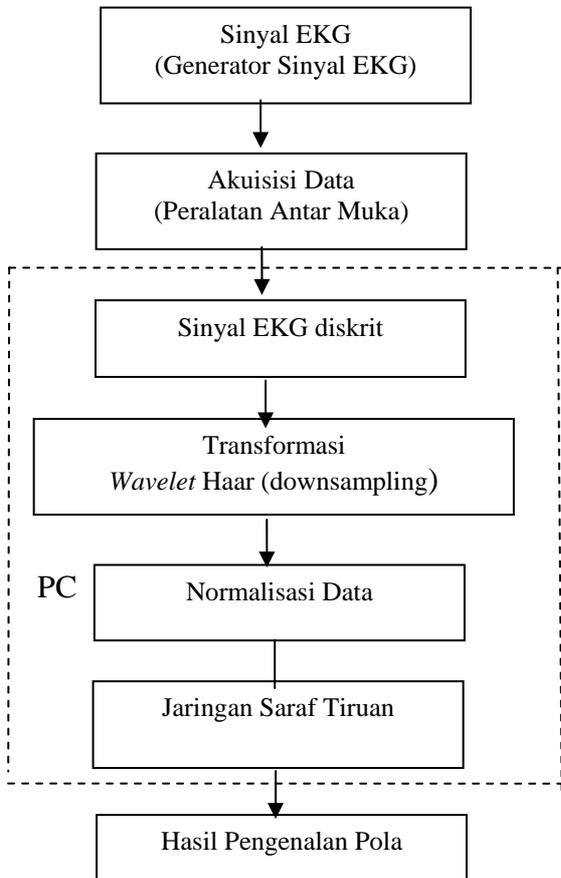
ini dilakukan sampai tiga kali (level3) sehingga jumlah data sinyal menjadi sebanyak 128. Bagian sinyal yang diambil adalah koefisien aproksimasi c(A) karena bagian koefisien detail (cD) merupakan noise yang menyertai sinyal. Gambar 3 adalah koefisien aproksimasi hasil proses *downsampling* samapi level ke-3.



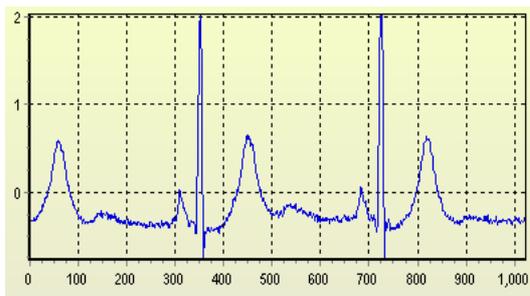
Gambar 1. Flowchart Learning dgn LM

Hasil *downsampling* ini dirubah kedalam bentuk spektrum frekuensi (sehingga menghasilkan data dengan jumlah setengah frekuensi sampling (fs=360Hz) yaitu 180 data. Dari hasil pengamatan, spektrum dari data tersebut dapat diambil mulai

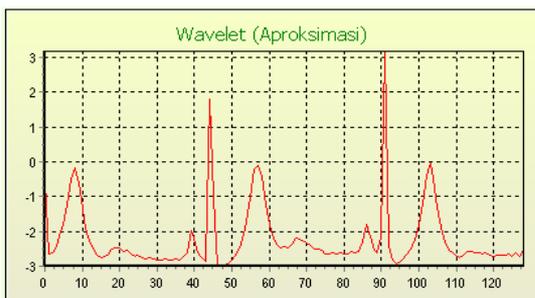
dari data ke-1 sampai 100 karena data ke-101 sampai 180 hampir sama untuk kelima masing-masing sinyal. Data ini dinormalisasi terlebih dahulu dengan range dari 1 sampai 0 normalisasi



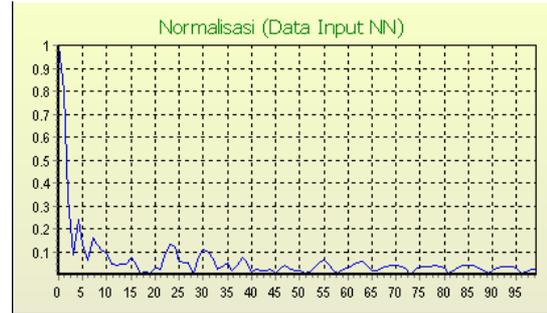
Gambar 2. Sistem Pengenalan Pola Sinyal EKG



Gambar 3. Grafik Sinyal Keluaran dari ADC.



Gambar 4. Koefisien Aproksimasi

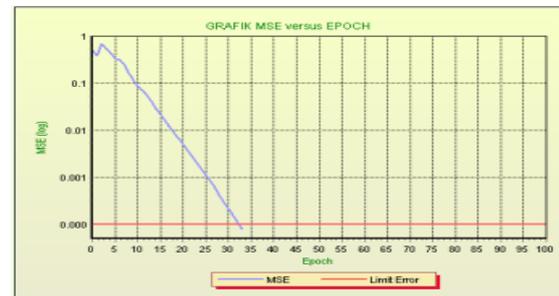


Gambar 5. Spektrum Sinyal yang Sudah dinormalisasi

Untuk pengujian digunakan kembali data generator dimana setiap kali pengambilan data akan didapat data yang random (karena setiap pengambilan sinyal data awalnya tidak selalu sama) dan ini digunakan untuk proses *mapping* secara *realtime*. Perangkat lunak yang digunakan dalam penelitian ini adalah Bahasa pemrograman Delphi 7.

3. Hasil dan Pembahasan

Untuk melihat unjuk kerja dari pengenalan pola ini dilakukan dua parameter yaitu efisiensi dari proses pelatihan dan keberhasilan pengenalan pola.

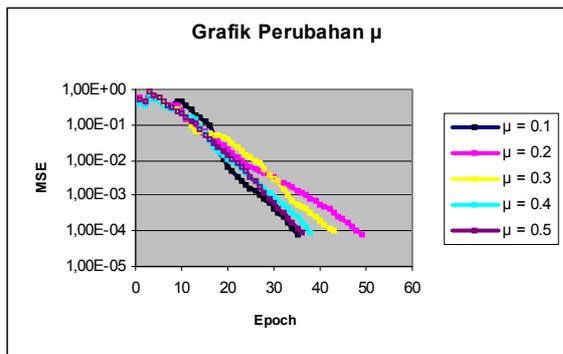


Gambar 6. Grafik learning

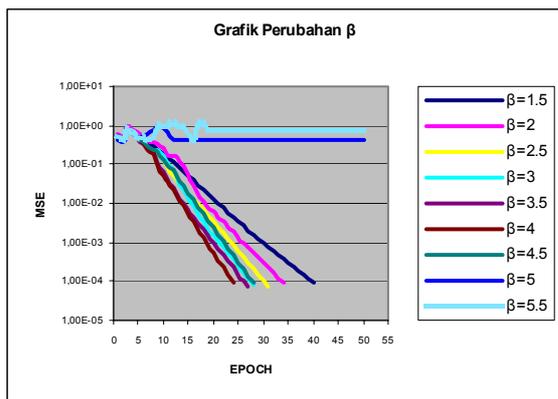
Gambar 5 adalah grafik Sum Square Error (SSE) proses learning Jaringan saraf tiruan (JST) yang digunakan pada sistem ini menggunakan jenis multi layer perceptron. Lapisan input terdiri dari 100 unit yang merupakan masukan dari hasil spektrum sinyal ternormalisasi. Lapisan tersembunyi 15 uni dan lapisan output terdiri atas lima unit yang akan mengeluarkan nilai berkisar 1 dan 0. Masing-masing unit akan berfungsi untuk mengklasifikasi satu jenis sinyal dengan melakukan pengambilan keputusan salah satu unit akan bernilai paling tinggi (satu) sedangkan yang lain mendekati nol.

Pengujian konstanta *learning* μ ini bertujuan untuk melihat pengaruh perubahan μ ini terhadap proses *learning*. Pada pengujian ini nilai awal μ dimulai dari 0.1 sedangkan nilai β dibuat tetap = 2. Pada Gambar 4.7 terlihat pada $\mu = 0.1$ konvergen tercapai pada iterasi disekitar 35. Pada iterasi berikutnya untuk nilai $\mu = 0.2$ jumlah

iterasi bertambah sampai 50 iterasi, sedangkan untuk nilai $\mu = 0, 4$ dan $0, 5$ jumlah iterasi berkurang kembali sampai 34 iterasi. Dari sini dapat disimpulkan perubahan μ dapat memperlambat iterasi. Perubahannya itu juga tergantung pada nilai awal saat random bobot dan bias.

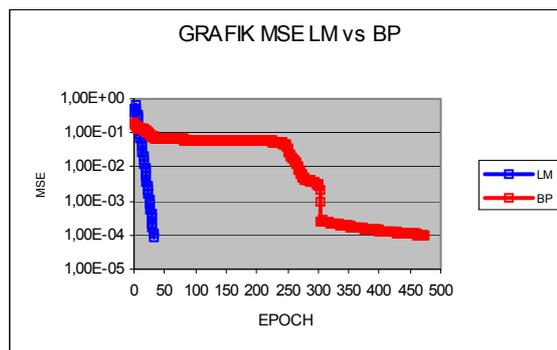


Gambar 7. Perubahan konstanta μ terhadap learning



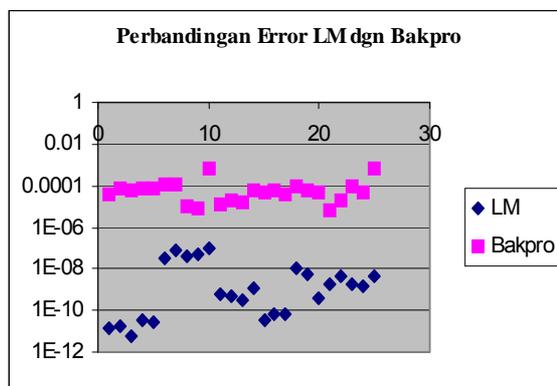
Gambar 8. Perubahan Konstanta β terhadap learning

Pengujian faktor pengali β ini bertujuan untuk melihat pengaruh perubahan β terhadap kecepatan learning. Pada pengujian ini nilai β diubah-ubah mulai dari 1 sampai 6. Dari Gambar 7 dapat dilihat bahwa untuk $\beta = 1.5$ jumlah iterasi yang dibutuhkan untuk mencapai konvergen sekitar 40 iterasi. Dengan kenaikan nilai β proses iterasi semakin cepat hal ini disebabkan oleh nilai μ semakin kecil karena dibagi oleh nilai β yang semakin besar sehingga proses invers matrik semakin cepat. Akan tetapi pada nilai $\beta = 5$ pada awalnya terjadi osilasi pada penurunan nilai error sampai iterasi sekitar 10 iterasi dan setelah itu tidak terjadi lagi penurunan error hal ini disebabkan karena terjadi proses pembagian dengan bilangan yang sangat kecil sekali pada invers matrik untuk perbaikan pembobot pada persamaan.



Gambar 10. Perbandingan Grafik Learning LM & BP

Gambar 10 memperlihatkan perbandingan proses training metode LM dan metode backpropagation ditinjau dari segi banyaknya iterasi yang dilakukan. Grafik error menggunakan metode LM digambarkan pada garis biru, terlihat bahwa error konvergen pada iterasi ke-36. Pada metode LM grafik error turun secara drastis membentuk garis yang linier. Garis merah menunjukkan error untuk metode backpropagation, dimana grafik tersebut turun secara perlahan dan mencapai konvergen pada iterasi ke-480



Gambar 9. Perbandingan Error Learning LM & BP

4. Kesimpulan

Dari hasil pengujian dapat diambil kesimpulan bahwa semakin kecil konstanta learning μ jumlah iterasi semakin kecil dan semakin besar nilai faktor pengali β dapat mempercepat iterasi. Dengan konfigurasi jaringan yang sama iterasi dengan algoritma Levenberg-Marquardt (35 iterasi) lebih sedikit dibandingkan dengan backpropagation standar (sekitar 550 iterasi). Pengujian dengan data learning error terkecil pada LM Sekitar 1×10^{-6} dan error terbesar sekitar 1×10^{-5} sedangkan dengan BP error terkecil sekitar 1×10^{-5} dan error terbesar sekitar 1×10^{-6} .

Daftar Pustaka

- [1] Leslie Crowell. (1996). *Biomedical Instrumentation and Measurement*, Prentice Hall of India, New Delhi.
- [2] Oliver Rioul, Martin Vitterli. (1991). Wavelets and Signal Processing. *IEEE SP Magazine*.
- [3] Supeno. (2005). Analisis Multi Resolusi Data Seismik Dengan Menggunakan Transformasi Wavelet. *Tesis Magister*. Jurusan Fisika Fakultas MIPA. ITS Surabaya.
- [4] Laurene Fausett. (1994). *Fundamentals of Neural Networks*. Prentice-Hall International, Inc. New Jersey, USA.
- [5] Rahmat. dkk. (2005). Pengenalan Pola Sinyal EKG menggunakan JST dengan Algoritma Levenberg-Marquardt. *Seminar Nasional Pasca Sarjana V ITS Surabaya*.
- [6] Martin T Hagan. dkk. (1994) Training Feedforwaed Network with the Marquardt Algorithm. *IEE Transactions on Neural Network*. Vol 5 No 6.
- [7] N. N. R. Ranga Suri. dkk. *Paralell Levenberg Marquardt-Baesd Neural Network Training on Linux Clusters-a Cases Studi*. AI and Neural Networks Group Center for Artificial Intelligence & Robotics. Bangalore, University of Mysore.
- [8] Syed Muhammad Akhil Burney.dkk.(2004) *Levenberg Marquard Algorithm for Karachi Stock Exchage Share Rates Forescasting*. International Journal of Computation Inteligence. Volume 1 Number 2 ISSN : 1304 - 4508
- [9] Deepak Misrha. dkk (2005). *Levenberg Marquardt Learning Algorithm for Integrate – and Fire Neuron Model*. Neural Information Processing- Letter and Reviews. Vol 9 NO. 2 November.

