

Klasifikasi Pergerakan Jari Tangan Berdasarkan Sinyal EMG Menggunakan Stacked Denoising Autoencoder untuk Mengendalikan Tangan Prostetik

Echa Pangersa Sugianto Oeoen¹, Jondri², Untari Novia Wisesty³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹echaoeoen@students.telkomuniversity.ac.id, ²jondri@telkomuniversity.ac.id,

³untari@telkomuniversity.ac.id

Abstrak

Elektromiografi (EMG) adalah teknik penelitian yang berkaitan dengan perekaman sinyal *myoelectric*. Sinyal mioelektrik dibentuk oleh variasi fisiologis dalam keadaan selaput serat otot. Sinyal ini berguna untuk mendiagnosis kesalahan pada sistem saraf perifer. Penggunaan EMG juga bisa menjadi sumber utama dalam pengendalian tangan prostetik karena kenyamanan penggunaannya. Tujuan dari penelitian ini adalah untuk mengidentifikasi pergerakan jari tangan manusia melalui sinyal EMG dengan cara klasifikasi. Ada 4 jenis gelombang dalam penelitian ini yang di klasifikasikan yaitu *Literal, Grasp, Fist/Hook dan Tip*. Metode yang digunakan dalam penelitian ini adalah *Deep Neural Network - Stacked Denoising Autoencoder*. Hasil pengujian penelitian ini menunjukkan akurasi tertinggi sebesar 94%. Dalam studi kasus yang diterapkan penulis mencetak tangan prostetik yang sebelumnya telah dikembangkan menggunakan 3D printing.

Kata kunci : *Deep Learning, Electromyograph, Tangan Prostetik, Deep Neural Network, Mechine Learning, Stacked Denoising Autoencoder.*

Abstract

Electromyography (EMG) is a research technique related to signal recording myoelectric. The myoelectric signal is formed by physiological variation in the state of the muscle fiber membrane. This signal is useful for diagnosing errors in the peripheral nervous system. The use of EMG can also be a major source of prosthetic hand control due to the convenience of its users. The purpose of this project is to identify the movement of human fingers through EMG signals by way of classification. There are 4 types of waves in this study which will be classified as *Literal, Grasp, Fist/Hook and Tip*. Method that used in this project is *Deep Neural Network - Stacked Denoising Autoencoder*. The highest accuracy generated in this study was 94%. In a case study the writer applied a prosthetic hand print that had previously been developed using 3D printing.

Keywords: *Deep Learning, Electromyograph, Prosthetic Hand, Deep Neural Network, Mechine Learning, Stacked Denoising Autoencoder.*

1. Pendahuluan

Teknologi yang ditemukan oleh Francesco Redi pada abad 16 telah merubah dunia kesehatan dibidang miologi, Redi menemukan sinyal elektrik dari otot manusia yang disebut sinyal EMG. Elektromiografi (EMG) adalah teknik penelitian yang berkaitan dengan perekaman sinyal *myoelectric*. Sinyal mioelektrik dibentuk oleh variasi fisiologis dalam keadaan selaput serat otot(1). Sinyal ini berguna untuk mendiagnosis kesalahan pada sistem saraf perifer.

Saat ini, sinyal EMG juga bisa menjadi sumber utama dalam pengendalian tangan prostetik karena kenyamanan dalam penggunaan tangan palsu ini menjadi lebih hidup dan menunjang aktifitas dalam kegiatan keseharian pengguna. Ada banyak penelitian yang mengembangkan tangan prostetik berdasarkan sinyal EMG, seperti *Bebionic* yang memungkinkan untuk merancang pergerakan tangan cukup tepat. Namun disisi lain harga dari lengan prostetik dari *bebionic* ini terlalu mahal sampai USD3000 (2).

Deep learning merupakan metode pembelajaran mesin yang model komputasinya bertingkat(3). Harapan dari penggunaan deep learning adalah menghasilkan representasi data yang akurat. Deep learning memiliki beberapa jenis metode pemodelan, salah satunya adalah *Deep neural Network*. *Deep neural network* adalah pengembangan dari jaringan saraf tiruan yang menggunakan banyak *hidden layer*, metode *deep neural network* yang digunakan dalam penelitian ini adalah *Stacked Denoising Autoencoder*.

Pada penelitian ini disusun membangun sebuah sistem yang dapat mengklasifikasi sinyal EMG untuk mengetahui jenis pergerakan jari tangan dari 2 *channel* sensor EMG. *Deep neural network* digunakan untuk mengklasifikasikan jenis sinyal EMG lalu hasilnya bisa dikirim ke tangan prostetik sebagai perintah untuk menggerakkan jari-jari pada tangan prostetik tersebut.

2. Studi Terkait

Tabel 1 menjelaskan penelitian - penelitian yang sebelumnya telah dilakukan yang berkaitan dengan topik yang dibahas dalam jurnal ini

Tabel 1. Penelitian Terkait

| Penulis | Metode | Akurasi |
|--|---------------------------------|---------|
| C. Sapsanis and G. Georgoulas and A. Tzes (4) | PCA and time-frequency features | 95.1% |
| Mahmoud Tavakoli, Carlo Benussi, Joao Luis Lourenco (5) | SVM | 90% |
| Zeghibib, Abdelhafid and Palis, Frank and Ben-Ouezdou, Fathi (6) | Fuzzy System | 80.39% |


Pada penelitian (4) mengklasifikasikan 6 jenis pergerakan tangan dengan menggunakan *2-channel EMG sensor*, yaitu *spherical*, *lateral*, *cylindrical*, *tip*, *hook* dan *palmar*. Teknik yang diusulkan terdiri dari dekomposisi sinyal EMG menggunakan *Empirical Mode Decomposition* yang diikuti oleh fitur ekstraksi menggunakan 8 fitur ekstraksi populer *Integrated Electromyogram (IEMG)*. Setelah fitur ekstraksi dilakukan reduksi dimensi menggunakan *Relief Algorithm*, lalu metode klasifikasi yang digunakan adalah *Principal Component Analysis*.

Penelitian yang dilakukan oleh (5) mengklasifikasikan tiga jenis gelombang, yaitu *Close (Cl)*, *Open (Op)*, *Change (Ch)* menggunakan 1 *channel* sensor EMG. Teknik yang diusulkan Dengan menggunakan *Support Vector Machine*

Pada penelitian (6) dengan 2 *channel* sensor EMG yang mengklasifikasikan 3 jenis gelombang pada pergerakan jari tangan, yaitu *Thumb (Th)*, *Middle (Mi)* dan *Pointer (Po)*. Teknik yang diusulkan dengan fitur ekstraksi menggunakan *Time Frequency Analysis based on Short Time Fourier Transform (STFT)* lalu diikuti dengan *Ellipsoidal delimitation* initialisation


2.1 Pengambilan Data EMG

Subjek terdiri dari 2 Pria dan 1 Wanita usia 22 - 23 tahun yang diminta untuk mengulangi 4 gerakan berikut Gambar 1 *Lateral (L)*: untuk memegang benda tipis, *Grasp (G)*: untuk memegang benda silinder seperti gelas, *Hook (H)*: untuk mendukung beban yang berat dan *Tip (T)*: untuk memegang benda kecil.



Gambar 1. 4 Jenis pergerakan jari tangan

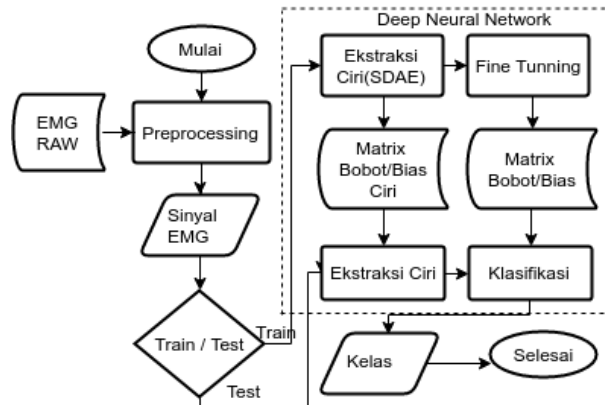
Pengambilan data dilakukan dengan membuat subjek memegang benda yang berbeda-beda. Kekuatan genggamannya di serahkan kepada subjek, sedangkan kecepatan genggamannya dibatasi selama 0,5 detik. Untuk setiap gerakan subjek diminta melakukannya berulang kali sebanyak 80 kali dengan menggunakan sensor myoware pada tingkat sampling 50hz dengan peletakan sensor menurut (7) seperti pada gambar 2



Gambar 2. Peletakan sensor Myoware (7)

dari 960 data maka dibagi menjadi 2 bagian yaitu 672 data latih dan 288 data uji.

3. Rincian Perancangan Sistem




Gambar 3. Flowchart sistem traning dan testing

Gambar 3 merupakan flowchart dari sistem yang dibangun: Pada tahap training, terdapat proses *pre-train* untuk melakukan ekstraksi ciri menggunakan DAE ke dalam beberapa *level*. Setelah ekstraksi ciri selesai, kemudian bobot hasil *pre-train* (bobot setiap *encoder*) dijadikan sebagai bobot pada *Deep Neural Network* (DNN) sesuai banyaknya level SDAE untuk dilakukan *fine tuning*.

3.1 Preprocessing - EMG Envelope

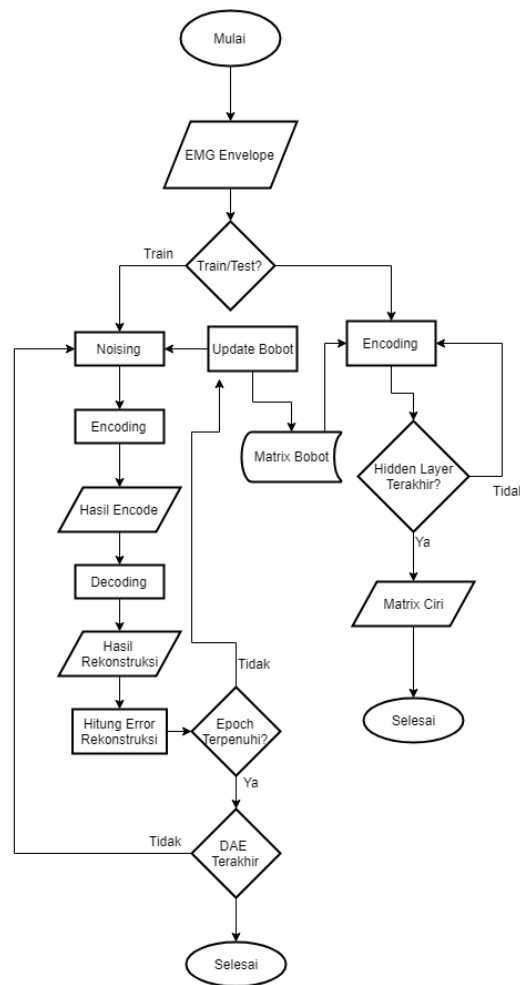
Preprocessing dilakukan agar data didapat dengan kualitas yang siap untuk dipelajari oleh sistem. Dalam sinyal EMG, *Preprocessing* bisa juga disebut sebagai *EMG Envelope*. *Envelope* sinyal EMG merupakan sinyal EMG yang telah melalui proses *full wave rectification*, *filtering*, dan *smoothing* dari raw sinyal EMG. *Envelope* dari raw sinyal EMG ini berguna untuk mengetahui waktu aktif otot dan mengukur *level* aktivasi (8).



(a) EMG Envelope (9)

3.2 Ekstraksi ciri

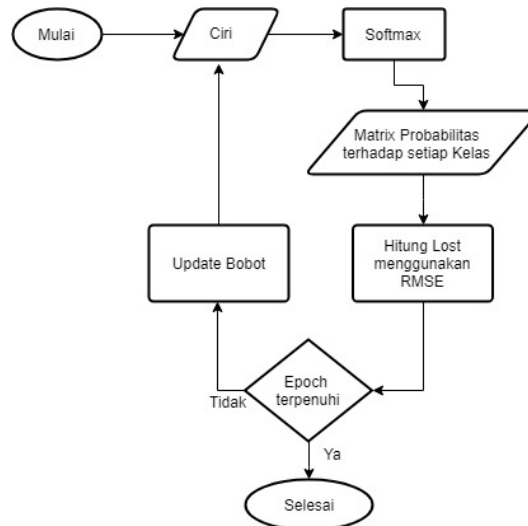
Sistem melakukan ekstraksi ciri terhadap data EMG menggunakan *Stacked Denoising Autoencoder*. Pada setiap *level* DAE input akan mengalami perusakan dengan diberikan *noise*, kemudian DAE melakukan *encode* dan *decode* untuk merekonstruksi data EMG. Hasil rekonstruksi hanya akan digunakan untuk menghitung *reconstruction error*. Sedangkan data yang akan digunakan untuk tahap berikutnya adalah hasil *encode* sebagai input terhadap *level* DAE yang lebih tinggi atau *fine tuning*.



Gambar 5. Flowchart ekstraksi ciri menggunakan Stacked Denoising Autoencoder

3.3 Fine Tuning

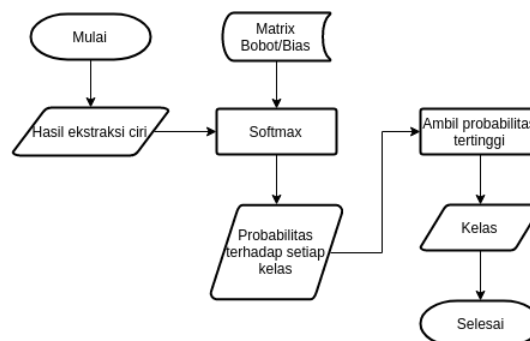
Setelah ekstraksi ciri didapatkan dari SDAE, lalu sistem akan memetakan setiap sampel terhadap seluruh kelas dengan menghitung nilai probabilitasnya menggunakan *softmax regression*. Pada layer ini diberlakukan juga algoritma *backpropagation* untuk mendapatkan bobot optimal agar setiap sampel terpetakan dengan benar sesuai dengan jenis pergerakan jari tangannya.



Gambar 6. Flowchart Finetuning

3.4 Klasifikasi

Klasifikasi penelitian ini dilakukan dengan menggunakan algoritma *softmax regression* yang telah terlatih. Kemudian penentuan kelas terhadap data tersebut dilakukan dengan cara memilih indeks neuron yang memiliki nilai probabilitas tertinggi.



Gambar 7. Flowchart klasifikasi

4. Hasil dan Pembahasan

4.1 Pengujian Sistem

Penelitian ini menerapkan beberapa pengujian terhadap sistem yang telah dijelaskan pada bab sebelumnya. Pengujian dilakukan guna memperoleh parameter yang optimal sehingga sistem dapat menghasilkan performansi yang terbaik dalam melakukan klasifikasi.

4.2 Tujuan Pengujian

Tujuan pengujian ini adalah sebagai berikut:

1. Mengetahui pengaruh jumlah *Layer* DAE terhadap tingkat akurasi agar mendapatkan model terbaik

2. Mengetahui pengaruh jenis fungsi aktivasi terhadap tingkat akurasi agar mendapatkan model terbaik
3. Mengetahui pengaruh jumlah data latih terhadap tingkat akurasi agar mendapatkan model terbaik

4.3 Skenario Pengujian


Dalam melakukan skenario pengujian terdapat parameter-parameter konstan dan parameter uji. sedangkan parameter uji merupakan parameter yang dianalisis. Tabel 2 menunjukkan parameter-parameter konstan

Tabel 2. Parameter konstan

| parameter | Nilai |
|---------------------------|--|
| Jenis Noise | Gaussian |
| Noise | 0.4 |
| Jumlah Epoch Pre-training | 10000 |
| Jumlah Epoch Fine-tuning | 30000 |
| Ukuran Batch | 200 |
| Optimizer Pretrain | Adam |
| Parameter Adam | alpha = 0.0008, beta1 = 0.9, beta2 = 0.9999 |
| Optimizer Finetune | Adam |
| Parameter Adam | alpha = 0.0000085, beta1 = 0.9, beta2 = 0.9999 |

4.3.1 Skenario I: Pengaruh jumlah Layer DAE

Kedalaman SDAE yang diuji yaitu 2 sampai 5 level. Berdasarkan gambar 8, performansi terbaik dihasilkan pada kedalaman 3 Layer




Gambar 8. Hasil Pengujian Pengaruh Jumlah Layer SDAE

Berdasarkan gambar 8, bisa disimpulkan bahwa kedalaman *layer* cukup mempengaruhi hasil akurasi model SDAE, akurasi terbaik dihasilkan pada 2 *layer* yaitu 94% dan tingkat akurasi cenderung menurun pada *layer* berikutnya.

4.3.2 Skenario II: Pengaruh Jenis Fungsi aktivasi

Pengujian skenario II dilakukan menggunakan 3 jenis fungsi aktivasi, yaitu relu, sigmoid, dan tanh, menggunakan parameter yang sama dengan pengujian skenario I dengan jumlah *layer* 3.




Gambar 9. Hasil Pengujian Pengaruh Jumlah Layer SDAE

Berdasarkan gambar 9, performansi terbaik dihasilkan pada fungsi aktivasi sigmoid dengan nilai akurasi mencapai 94%, namun tingkat akurasi fungsi aktivasi relu dan sigmoid masih cukup tinggi yaitu 90% dan 89%

4.3.3 Skenario II—: Pengaruh Jumlah data Latih

Salah satu kelebihan *Stacked Autoencoder* dan ketturunannya adalah dapat mengatasi permasalahan kecilnya jumlah dataset yang dilatih. Model yang diuji adalah model yang mempunyai hasil akurasi terbaik dari skenario sebelumnya yaitu model DNN dengan kedalaman 3 Layer dengan fungsi aktivasi sigmoid. pengujian dilakukan sebanyak 2 kali dengan jumlah data uji dan data latih sama dan yang kedua jumlah data latih 30% dan jumlah data uji 70% yaitu data latih sebanyak 288 dan data uji sebanyak 672



Gambar 10. Hasil Pengujian Pengaruh Jumlah Data Latih

Berdasarkan gambar 10, sistem tetap menghasilkan tingkat akurasi yang cukup tinggi walaupun jumlah data yang dilatih lebih sedikit dari jumlah data yang di uji.

5. Kesimpulan Dan Saran

5.1 Kesimpulan

Berdasarkan hasil pengujian dari setiap skenario yang telah dilakukan, maka dapat diambil kesimpulan sebagai berikut:

1. Penelitian Klasifikasi pergerakan jari tangan menggunakan *Stacked Denoising Autoencoders* mendapat akurasi tertinggi sebesar 94%
2. Penggunaan fungsi aktivasi sigmoid lebih baik dibandingkan dengan penggunaan relu atau tanh
3. Akurasi klasifikasi menggunakan *Stacked Denoising Autoencoders* tetap tinggi walau data latih lebih sedikit dari pada data uji

5.2 Saran

Berdasarkan hasil pengujian dari setiap skenario yang telah dilakukan, dapat diberikan saran sebagai berikut:

1. Gunakan fungsi aktivasi yang lain seperti Leakyrelu dan Arctan untuk membandingkan hasil dari fungsi-fungsi aktivasi tersebut.
2. Diharapkan penelitian selanjutnya memperhatikan jumlah data sinyal perkelas, semakin banyak data dalam satu individu semakin baik dalam proses pelatihan datanya.

Daftar Pustaka

- [1] P. Konrad, *The ABC of EMG*. Noraxon U.S.A. Inc., 2006.
- [2] E. Markowitz, "Next-Gen Prosthetics Will Blow Your Mind," <http://www.vocativ.com/money/industry-/prosthetic-boom-3d-printed-mind-controlled-limbs/index.html>, 2014, [Online; accessed 15-10-2017].
- [3] Y. Bengio, "Deep learning of representations: Looking forward," *CoRR*, vol. abs/1305.0445, 2013. [Online]. Available: <http://arxiv.org/abs/1305.0445>
- [4] C. Sapsanis, G. Georgoulas, and A. Tzes, "Emg based classification of basic hand movements based on time-frequency features," in *21st Mediterranean Conference on Control and Automation*, June 2013, pp. 716–722.
- [5] J. L. L. Mahmoud Tavakoli, Carlo Benussi, "Single channel surface emg control of advanced prosthetic hands: a simple, low cost and efficient approach," 2017.
- [6] A. Zeghibib, F. Palis, and F. Ben-Ouezdou, "Emg-based finger movement classification using transparent fuzzy system." pp. 816–821, 2005. [Online]. Available: <http://dblp.uni-trier.de/db/conf/eusflat/eusflat2005.html#ZeghibibPB05>
- [7] O. Bionics, "User guide for brunel hand," 2017, bEETROOT V1.0 FIRMWARE USER GUIDE FOR BRUNEL HAND, <https://openbionicslabs.com/obtutorials/>.
- [8] P. M. H. Putra Darma Setiawan, Wibawa Adhi Dharma, "Klasifikasi sinyal emg pada otot tungkai selama berjalan menggunakan random forest," *Inotera*, vol. 1, pp. 51–56, Dec. 2016.
- [9] I. Stirn, T. Jarm, V. P. Kapus, and V. Strojnik, "Evaluation of mean power spectral frequency of emg signal during 100 metre crawl," *European Journal of Sport Science*, vol. 13, no. 2, pp. 164–173, 2013. [Online]. Available: <https://doi.org/10.1080/17461391.2011.630100>