

KLASIFIKASI SINYAL ECG MENGGUNAKAN DEEP LEARNING DENGAN STACKED DENOISING AUTOENCODERS

ECG SIGNAL CLASSIFICATION USING DEEP LEARNING WITH STACKED DENOISING AUTOENCODERS

Ilham Muhammad¹, Jondri, M.Si.², Untari Novia Wisesty, S.T, M.T.³

^{1,2,3}Prodi S1 Teknik Informatika, Fakultas Informatika, Universitas Telkom

ilhammaziz27@gmail.com, jondri@telkomuniversity.ac.id, untari@telkomuniversity.ac.id

Abstrak

Aritmia merupakan kondisi jantung yang berdetak tidak sebagaimana mestinya, bisa berdetak terlalu cepat, lambat, atau berdetak dengan pola yang tidak beraturan. Akibat jantung yang tidak berdetak dengan normal, maka peredaran darah pun menjadi tidak normal juga. Sehingga berpengaruh terhadap kondisi kesehatan tubuh. Untuk mendiagnosa aritmia, salah satu metode yang digunakan ialah dengan membaca pola sinyal jantung yang disebut dengan Electrocardiogram (ECG). Deep Learning merupakan suatu metode pembelajaran mesin yang memungkinkan komputasi dalam level abstraksi bertingkat. Salah satu jenis deep learning yaitu Stacked Denoising Autoencoders (SDAE) [7]. SDAE digunakan untuk merekonstruksi suatu data yang telah dirusak agar tetap memiliki informasi yang mendekati data yang sebenarnya. Pada tugas akhir ini, penulis merancang sebuah sistem yang dapat mendeteksi aritmia menggunakan metode SDAE sebagai tahap pretraining, dan Softmax Regression untuk melakukan fine tuning. Akurasi tertinggi yang dihasilkan dalam mengklasifikasikan sinyal ECG yaitu sebesar 98.91%.

Kata kunci : Aritmia, Electrocardiogram, Deep Learning, Stacked Denoising Autoencoders, Softmax Regression, Fine Tuning.

Abstract

Arrhythmia is a condition of the heart that beats abnormally, it may beat too fast, slow, or beat with an irregular pattern. Because the heart beating abnormally, then the blood circulation becomes abnormally too. Therefore it influences to the health condition of the body. To diagnose an arrhythmia, one of the methods used is by reading the cardiac signal pattern called electrocardiogram (ECG). Deep Learning is a branch of machine learning method that allows computing model in multi level abstraction. Stacked Denoising Autoencoders (SDAE) is one of deep learning structure models. SDAE used to reconstruct the data by damaging it so then it had informations that approaching the actual data. In this final project, the author designed a system that can find arrhythmias using SDAE as feature extraction and Softmax Regression as fine tuning. Highest accuracy yield by the system is 98.91%.

Keywords: Arrhythmia, Electrocardiogram, Deep Learning, Stacked Denoising Autoencoders, Softmax Regression, Fine Tuning.

1. Pendahuluan

Dalam bidang medis untuk mengetahui kondisi jantung seseorang dapat dilakukan dengan cara memantau aktivitas jantung orang tersebut. Jantung yang sehat ditandai dengan detak yang beraturan, sebaliknya detak yang tidak beraturan menandakan terdapat kelainan pada jantung tersebut. Aritmia adalah kondisi jantung berdetak dengan irama yang tidak beraturan sehingga menyebabkan peredaran darah ke seluruh tubuh menjadi buruk [3]. Hal tersebut dapat menyebabkan berbagai macam penyakit. Secara alamiah aritmia dapat didiagnosa dengan beberapa gejala seperti palpitasi, pusing, sesak nafas, dan sebagainya. Namun bisa juga aritmia terjadi tanpa gejala, dan bisa

juga gejala-gejala tersebut bukan merupakan gejala aritmia. Salah satu metode lain untuk mendiagnosa gejala aritmia ialah dengan alat bernama elektrokardiograf.

Elektrokardiograf akan menampilkan rangkaian detak jantung seseorang dalam bentuk gelombang yang dikenal dengan istilah electrocardiogram (ECG). Jantung yang normal ditandai dengan pola gelombang yang teratur. Sedangkan jantung yang menderita aritmia ditandai dengan terdapat pola gelombang yang tidak beraturan. Pada umumnya untuk mendiagnosa jenis aritmia yang diderita, dokter melakukannya dengan cara mengamati gelombang ECG pada layar elektrokardiograf. Tentu hal tersebut akan menyulitkan karena tidak diketahui kapan terjadinya distorsi gelombang. Terdapat beberapa penelitian yang telah mencoba mengatasi masalah tersebut, antara lain yang dilakukan oleh [4] mengklasifikasikan 4 jenis aritmia menggunakan DAE dan softmax didapatkan akurasi sebesar 91.3%. Kemudian [10] dengan menggunakan metode PCA dan LS-SVM didapatkan akurasi sebesar 98.11% untuk 5 jenis aritmia. Ada pula penelitian yang menerapkan metode deep learning yaitu yang dilakukan oleh [2] menggunakan DAE dan softmax untuk mengklasifikasikan 6 jenis aritmia, didapatkan akurasi sebesar 99.5%.

Deep learning merupakan suatu metode pembelajaran mesin yang memungkinkan pemodelan komputasi dalam berbagai tingkat abstraksi [5]. Harapan dari penggunaan deep learning adalah menghasilkan representasi data yang lebih baik dari abstraksi yang bertingkat. Deep learning memiliki beberapa jenis metode berdasarkan pemodelan struktur layer -nya. Salah satu jenis deep learning yaitu Stacked Denoising Autoencoders (SDAE) [6]. SDAE digunakan untuk merekonstruksi data dengan cara memberikan noise terhadap input dalam beberapa tingkat abstraksi. Pada dasarnya SDAE merupakan Denoising Autoencoder yang ditumpuk serupa dengan Stacked Autoencoders.

Pada tugas akhir ini penyusun membangun sebuah sistem yang dapat mengklasifikasi sinyal ECG untuk diketahui jenis aritmia apa yang dialami. SDAE digunakan untuk merekonstruksi sinyal ECG tersebut dan mendapatkan fitur ekstraksi, setelah itu hasil rekonstruksi tersebut dimasukkan ke dalam layer softmax untuk fine tuning terhadap jenis aritmia tertentu.

2. Metode dan Dataset

2.1. Dataset

Dataset yang digunakan adalah dataset mitdb. Setiap file dataset terdiri dari tiga atribut, yaitu atribut waktu dan dua atribut channel rekaman ECG. Channel yang digunakan adalah channel elektroda MLII (Modified Limb Lead II). Lead tersebut dipilih karena menghasilkan amplitudo yang lebih tinggi pada gelombang QRS normal dibanding elektroda yang lain. Penulis memilih lima jenis gelombang untuk diklasifikasikan, karena memiliki jumlah sampel yang cukup untuk kebutuhan training dan testing. Kelima gelombang tersebut merupakan jenis gelombang yang digunakan juga pada penelitian [2] dan [4]. Lima gelombang tersebut yaitu:


- 1) Normal beat(N): 2274 sampel.
- 2) Left Bundle Branch Block(L): 706 sampel.
- 3) Right Bundle Branch Block(R): 1967 sampel.
- 4) Atrial Premature Contraction(A): 789 sampel.
- 5) Ventricular Premature Contraction(V): 1951 sampel.

Sampel dipilih secara random dari setiap file, dan dilabeli secara manual berdasarkan file anotasi. Kemudian dataset tersebut dibagi menjadi tiga bagian yaitu data latih, data validasi, dan data testing. Seluruh data digunakan saat pretraining menggunakan SDAE untuk mendapatkan ciri dari setiap data. Kemudian saat fine-tuning data yang digunakan untuk melatih sistem hanya data latih, serta data validasi untuk validasi. Data testing digunakan untuk mengevaluasi hasil training sistem.

2.2. Stacked Denoising Autoencoder

Denoising Autoencoder (DAE) merupakan model pengembangan dari Autoencoder. Secara intuitif, DAE melakukan dua hal, yaitu mempertahankan informasi pada input dan mengembalikan informasi dari input yang telah dirusak [7]. DAE memiliki kemampuan untuk mencari representasi yang lebih luas dari dari suatu input, karena DAE berusaha memprediksi nilai-nilai yang hilang atau rusak dari suatu data. Sedangkan Stacked Denoising Autoencoders (SDAE) merupakan metode penumpukan beberapa Denoising Autoencoder untuk meningkatkan


kemampuannya dalam melakukan abstraksi atau ekstraksi ciri. Semakin tinggi level-nya semakin abstrak pula ekstraksi cirinya [6]. Setiap level DAE akan mencari ciri dari DAE level sebelumnya dengan cara merekonstruksinya. Setiap hidden layer pada setiap level DAE menjadi input terhadap DAE level berikutnya, dan setiap input tersebut akan mengalami perusakan.



Gambar 2.1 Arsitektur Stacked Denoising Autoencoders

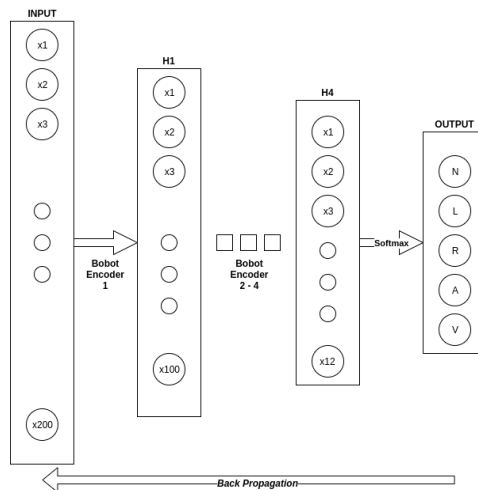
2.3. Rancangan Sistem

Gambar 3 merupakan flowchart dari sistem yang akan dibangun:



Gambar 2.2 Alur rancangan sistem

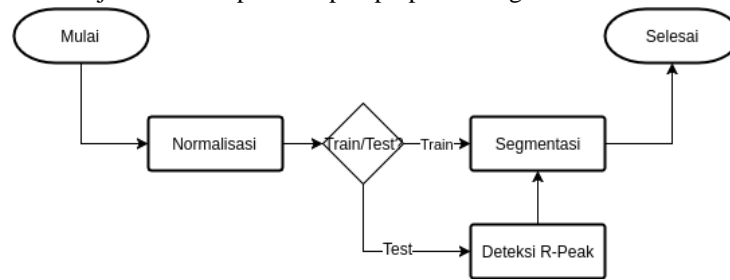
Pada tahap training, terdapat proses pre-train untuk melakukan ekstraksi ciri menggunakan SDAE dalam beberapa level. Setelah ekstraksi ciri selesai, kemudian bobot hasil pretrain yaitu bobot pada setiap encoder dijadikan sebagai bobot pada Deep Neural Network (DNN) sesuai banyaknya level SDAE untuk dilakukan fine tuning, lihat gambar 4.



Gambar 2.3 Struktur Deep Neural Network

2.4. Preprocessing

Preprocessing dilakukan untuk mendapatkan data dengan kualitas lebih baik dan siap untuk dilakukan dipelajari sistem. Gambar 5 menjelaskan tahapan-tahapan preprocessing.



Gambar 2.4 Alur preprocessing

2.5. Normalisasi


Normalisasi dilakukan untuk menyeragamkan range amplitudo sinyal. Normalisasi yang dilakukan yaitu pada range -0.95 sampai 0.95 dengan perhitungan sebagai berikut:

$$\hat{x} = (a - b) \frac{x - \min(x)}{\max(x) - \min(x)} + b$$

Dengan x adalah nilai sebenarnya, a dan b sebagai batas atas dan bawah, dan \hat{x} adalah nilai setelah dinormalisasi.

2.6. Segmentasi


Segmentasi dilakukan untuk mendapatkan satu bentuk gelombang P-QRS-T, dengan R-peak sebagai titik acuan. Nilai R-peak didapatkan dari file anotasi yang terdapat pada dataset. Berdasarkan [4], satu gelombang ECG didapatkan dengan cara mengambil 99 sampel sebelah kiri R-Peak, dan 100 sampel sebelah kanan R-Peak seperti yang ditunjukkan pada gambar 6. Sehingga satu gelombang ECG memiliki 200 sampel dan cukup untuk mengandung gelombang P-QRS-T.



Gambar 2.5 Ilustrasi Segmentasi

2.7. Ekstraksi Ciri

Berdasarkan gambar 8, sistem melakukan ekstraksi ciri terhadap representasi data ECG menggunakan DAE yang ditumpuk (Stacked Denoising Autoencoders). Pada setiap level DAE input akan mengalami perusakan dengan diberikan noise, kemudian DAE akan melakukan encode dan decode untuk merekonstruksi data ECG. Hasil rekonstruksi hanya akan digunakan untuk menghitung reconstruction error. Sedangkan data yang digunakan untuk tahap berikutnya adalah hasil encode sebagai input terhadap DAE level yang lebih tinggi atau fine tuning.




Gambar 2.8 Alur ekstraksi ciri

3. Hasil Eksperimen

Pengujian dilakukan terhadap lima jenis aritmia dan non-aritmia, yaitu:

- 1) Normal beat
- 2) Left Bundle Branch Block
- 3) Right Bundle Branch Block
- 4) Atrial Premature Contraction
- 5) Ventricular Premature Contraction

Pengujian dilakukan dalam beberapa skenario berdasarkan parameter kedalaman layer dan jenis noise. Hasil terbaik diperoleh pada skenario dengan jenis noise masking dengan corruption level sebesar 0.25 di kedalaman 3 layer.



4. Kesimpulan

Berdasarkan hasil pengujian dan analisis yang telah dilakukan, maka dapat diambil kesimpulan sebagai berikut:

- 1) Pendeteksian lima jenis aritmia dapat dilakukan menggunakan Deep Learning dengan Stacked Denoising Autoencoders dengan akurasi tertinggi sebesar 98.91%.
- 2) Penggunaan untied-weight dan masking noise dengan corruption level sebesar 0.25 pada level kedalaman 2 layer menghasilkan performansi tertinggi.

- 3) Penggunaan untied-weight menghasilkan rekonstruksi yang lebih beragam, sehingga performansi setiap kali training mungkin sangat berbeda. Mungkin lebih baik dan mungkin tidak. Aritmia jenis PAC selalu menghasilkan akurasi yang lebih rendah karena bentuk gelombang jenis PAC hampir sama dengan jenis Normal.

Daftar Pustaka

- [1] S. Goldsworthy and L. Graham, *Compact Clinical Guide to Arrhythmia and 12-Lead EKG Interpretation*. Springer, 2015.
- [2] M. A. Rahhal, Y. Bazi, H. AlHichri, N. Alajlan, F. Melgani, and R. Yager, "Deep learning approach for active classification of electrocardiogram signals," *Information Sciences*, 2016.
- [3] R. J. Martis, R. Acharya, Mandana, I. Lajoie, Ray, and C. Chakraborty, "Application of principal component analysis to ecg signals for automated diagnosis of cardiac health," *Expert Systems with Applications*, vol. 39, pp. 11792–11800, 2012.
- [4] J. Yang, Y. Bai, F. Lin, M. Liu, Z. Hou, and X. Liu, "A novel electrocardiogram arrhythmia classification method based on stacked sparse auto-encoders and softmax regression," *International Journal Machine Learning and Cyber*, 2017.
- [5] Y. Bengio, "Deep learning of representations: Looking forward," *Statistical language and speech processing lecture notes in computer science*, pp. 1–37, 2013.
- [6] P. Vincent, H. Larochelle, Y. Bengio, I. Lajoie, and P.-A. Manzagol, "Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion," *Journal of machine learning research*, vol. 11, pp. 3371–3408, 2010.
- [7] P. Vincent, H. Larochelle, Y. Bengio, I. Lajoie, and P.-A. Manzagol, "Extracting and composing robust features with denoising autoencoders," *Proceedings of the 25th International Conference on Machine Learning - ICML '08*, 2008.
- [8] Kathirevel, S. Manikandan, prasanna, and oman, "An efficient r-peak detection based on new nonlinear transformation and first-order gaussian differentiator," *Cardiovascular Engineering and Technology*, vol. 2, pp. 408–425, 2011.