

Klasifikasi Sinyal EKG Menggunakan Deep Belief Network dengan Restricted Boltzmann Machine

Ali Zainal Abidin Assajjad¹, Jondri, S.Si., M.Si.², Untari Novia Wisesty, S.T., M.T.³

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

¹alizabidin@student.telkomuniversity.ac.id, ²jondri@telkomuniversity.ac.id,

³untarinw@telkomuniversity.ac.id

Abstrak

Jantung adalah salah satu organ terpenting bagi manusia. Kerusakan atau bahkan berhentinya kerja jantung dapat berakibat sangat fatal. Ketidaknormalan detak jantung manusia disebut dengan aritmia. Salah satu cara untuk melakukan diagnosis terhadap aritmia adalah dengan Elektrokardiogram (EKG). EKG merupakan salah satu metode diagnosis detak jantung dengan merekam aktivitas fisiologis jantung melalui elektroda-elektroda yang dipasang di kulit dalam periode waktu tertentu. Beberapa metode ekstraksi fitur dan klasifikasi dilakukan untuk mengetahui jenis-jenis detak jantung mana saja yang tergolong ke dalam aritmia. Di dalam Tugas Akhir ini digunakan *Deep Belief Network* (DBN) yang dibangun dari *Stacked Restricted Boltzmann Machine* (RBM). Sistem yang dibangun mampu melakukan ekstraksi fitur dan mengklasifikasi data EKG dengan akurasi terbaik 91,939%.

Kata kunci: Klasifikasi, Elektrokardiogram, Aritmia, Deep Belief Network

Abstract

Heart is one of the most important organ in human. Heart damage or failure has a very fatal impact. Abnormality of human heartbeat is called arrhythmia. One way to diagnose arrhythmia is electrocardiogram (ECG). ECG is a heartbeat diagnosis method which records the physiological activity of heart using electrodes on the skin in certain unit of time. Several feature extraction and classification method are used to determine the types of heartbeat which belong to the arrhythmia. In this final task, Deep Belief Network (DBN) is constructed using Stacked Restricted Boltzmann Machine (RBM). The constructed system is able to extract features and classify ECG data with best accuracy 91.939%.

Keywords: Classification, ECG, Arrhythmia, Deep Belief Network

1. Pendahuluan

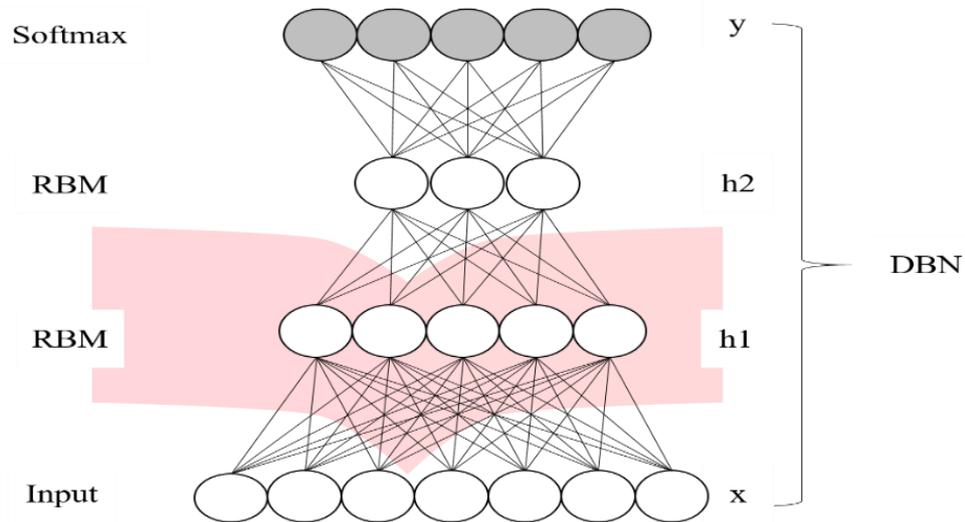
Latar Belakang

Berdasarkan data statistik *World Health Organization* (WHO), dari 17,5 juta orang yang meninggal dunia akibat penyakit kronis, 14,1 juta orang meninggal karena penyakit kardiovaskular. Terdapat 7,4 juta orang meninggal dunia karena jantung koroner dan 6,7 juta lainnya disebabkan karena stroke [1]. Penyakit kardiovaskular merupakan penyakit yang terjadi pada organ jantung dan pembuluh darah. Ketidaknormalan detak jantung manusia disebut dengan aritmia. Aritmia secara umum dibagi menjadi dua, detak jantung yang lebih cepat dari detak rata-rata disebut takikardia, sementara detak jantung yang lebih lambat disebut bradikardia. Salah satu cara untuk melakukan diagnosis terhadap aritmia adalah dengan Elektrokardiogram (EKG) [2]. EKG merupakan salah satu metode diagnosis detak jantung dengan merekam aktivitas fisiologis jantung melalui elektroda-elektroda yang dipasang di kulit dalam periode waktu tertentu. Untuk mengetahui fitur-fitur penting di dalam EKG, diperlukan pengamatan secara langsung oleh dokter ahli jantung. Hal tersebut tentu akan menyulitkan apabila diagnosis secara manual dilakukan untuk jumlah sinyal yang sangat banyak.

Beberapa penelitian telah menerapkan metode-metode *machine learning* untuk melakukan klasifikasi sinyal EKG. *Linear Discriminant* (LD) dengan *Wavelet Transform* (WT) untuk ekstraksi fitur dan fitur manual berupa *morphological features* memperoleh akurasi sebesar 78,00%, sementara *Support Vector Machine* (SVM) dengan WT, *Independent Component Analysis* (ICA), dan *Principal Component Analysis* (PCA) untuk ekstraksi fitur dan fitur manual berupa *internal features* memperoleh akurasi sebesar 86,40% [3]. Metode-metode tersebut membutuhkan *supervised dataset* sehingga kurang baik dalam menangani rekaman EKG dalam jumlah besar [4]. Penelitian lainnya telah menerapkan metode *Deep Learning* untuk melakukan klasifikasi sinyal EKG, diantaranya *Deep Neural Network* dengan *Stacked Denoising Auto-Encoder* yang memperoleh akurasi sebesar 89,30% [5] dan *Multistage Deep Belief Network* (DBN) dengan *Second Order Differential Plot* sebagai ekstraksi fitur diperoleh akurasi sebesar 96,10% [3].

Topik dan Batasannya

Berdasarkan latar belakang diatas, dalam Tugas Akhir ini digunakan salah satu metode *Deep Learning* untuk melakukan klasifikasi sinyal EKG. *Deep Learning* dapat mempelajari representasi fitur-fitur penting yang terkandung di dalam data *input* sehingga dapat melakukan ekstraksi fitur secara otomatis. Sistem yang dibangun yaitu *Deep Belief Network* (DBN). DBN merupakan *Neural Network* yang terdiri dari tumpukan *Restricted Boltzmann Machine* (RBM) dan diberikan sebuah *classifier* di *layer* terakhir. Berikut adalah model DBN dengan 2 RBM dan sebuah *Softmax Classifier*.



Gambar 1. Model DBN

Permasalahan-permasalahan yang dibahas dalam Tugas Akhir ini adalah bagaimana cara melakukan klasifikasi sinyal EKG menggunakan *Deep Belief Network*, bagaimana model *Deep Belief Network* yang baik untuk melakukan klasifikasi sinyal EKG, dan bagaimana performansi yang dihasilkan oleh *Deep Belief Network* dalam melakukan klasifikasi sinyal EKG.

Beberapa batasan dalam Tugas Akhir ini adalah data sinyal EKG yang digunakan merupakan data yang diperoleh dari MIT-BIH *Arrhythmia Database*. Data sinyal EKG dari MIT-BIH terdiri dari 2 *channel*, *modified limb lead II* dan salah satu dari *Modified leads V1, V2, V4, atau V5*, namun *channel* yang digunakan hanya *channel modified limb lead II* (MLII). Dari 48 rekaman data sinyal EKG yang tersedia, data rekaman ke-102, 104, 107, dan 217 tidak digunakan karena merupakan *paced beats* [4, 5, 6]. Keseluruhan data yang tersedia untuk data latih dan data uji masing-masing mencapai 50.000 data dimana sekitar 45.000 data didominasi oleh satu jenis sinyal EKG, sehingga dalam Tugas Akhir ini hanya digunakan sebagian *sample* untuk menyeimbangkan jumlah kelas data. *Sample* yang dipilih untuk data latih sebanyak 4092 segmen sinyal, sementara untuk data uji sebanyak 2754 segmen sinyal.

Tujuan

Berdasarkan permasalahan-permasalahan diatas, tujuan dari Tugas Akhir ini adalah membangun sistem berbasis *Deep Learning* untuk melakukan klasifikasi sinyal EKG menggunakan *Deep Belief Network*, menganalisis model *Deep Belief Network* yang baik untuk melakukan klasifikasi sinyal EKG, dan menganalisis performansi yang dihasilkan oleh *Deep Belief Network* dalam melakukan klasifikasi sinyal EKG.

Organisasi Tulisan

Laporan Tugas Akhir ini terbagi ke dalam beberapa bab, diantaranya:

1. Studi Terkait

Studi terkait memuat hasil-hasil dari penelitian terkait klasifikasi sinyal EKG yang pernah dilakukan sebelumnya.

2. Metodologi Penelitian

Metodologi penelitian membahas rancangan dan cara kerja sistem yang dibangun beserta data yang digunakan.

3. Evaluasi

Evaluasi membahas hasil serta analisis dari pengujian yang dilakukan berdasarkan skenario pengujian yang telah dirancang.

4. Kesimpulan

Kesimpulan memuat kesimpulan yang ditarik berdasarkan hasil dari pengujian yang dilakukan serta saran untuk pengembangan selanjutnya.

2. Studi Terkait

Beberapa penelitian yang pernah dilakukan terkait topik Tugas Akhir ini adalah klasifikasi menggunakan *Linear Discriminant* dengan *Wavelet Transform* dan *morphological features* sebagai ekstraksi fitur memperoleh akurasi sebesar 78,00% [3]. Penelitian lainnya menggunakan *Support Vector Machine* dengan *Internal Features*, *Wavelet Transform*, *Independent Component Analysis*, dan *Principal Component Analysis* sebagai ekstraksi fitur menghasilkan akurasi sebesar 86,40% [3]. Untuk metode klasifikasi sinyal EKG yang sudah menerapkan metode *Deep Learning* adalah klasifikasi menggunakan *Deep Neural Network* dengan *Stacked Denoising Auto-Encoder* yang memperoleh akurasi sebesar 89,3% [5] dan *Multistage Deep Belief Network* dengan *Second Order Differencial Plot* sebagai ekstraksi fitur diperoleh akurasi sebesar 96,10% [6].

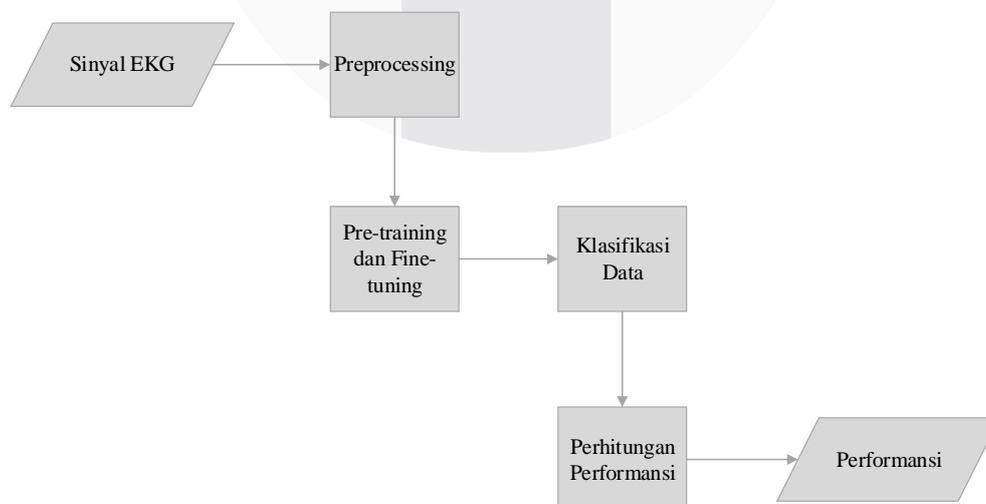
Tabel 1. Studi Terkait

Penulis	Metode	Akurasi (%)
Llamedo et al. 2011.	LD dengan <i>Wavelet Transform</i> dan <i>morphological features</i>	78,00
Ye et al. 2012.	SVM dengan <i>Internal Features</i> , <i>Wavelet Transform</i> , ICA dan PCA	86,40
Altan et al. 2016.	<i>Multistage</i> DBN dengan SODP	96,10
Luo et al. 2017.	DNN dengan SDAE	89,30

3. Metodologi Penelitian

Rancangan Sistem

Gambaran umum tentang aktivitas yang dilakukan dalam Tugas Akhir ini termuat dalam diagram dibawah ini.



Gambar 2. Diagram Alur Penelitian

Pada Tugas Akhir ini dibangun sebuah sistem klasifikasi sinyal EKG menggunakan *Deep Belief Network* (DBN) dengan *Restricted Boltzmann Machine* (RBM). Proses utama untuk melakukan klasifikasi sinyal EKG pada sistem yang dibangun terbagi ke dalam empat tahap, yaitu *preprocessing*, *training* dan *fine-tuning*, prediksi data, dan perhitungan performansi.

Pada tahap *preprocessing*, sinyal-sinyal EKG akan di *filter* menggunakan metode *filtering* yang umum digunakan pada penelitian klasifikasi sinyal EKG menurut [7] agar performansi klasifikasi dapat dibandingkan dengan penelitian-penelitian sebelumnya. *Filter* yang digunakan adalah dua *median filter* dan *Finite Impulse Response* (FIR). Setelah *filtering* selesai, sinyal EKG akan dinormalisasi dengan batas bawah 0,1 dan batas atas 0,9. Sinyal EKG yang telah ternormalisasi akan disegmentasi berdasarkan *r-peak* masing-masing.

Setelah *preprocessing* selesai, proses pelatihan DBN akan dimulai. DBN dilatih melalui 2 tahap, yaitu *pre-training* dan *fine-tuning*. Data latih akan digunakan untuk proses *training* DBN. Pada tahap *pre-training*, setiap *layer* RBM akan dilatih untuk melakukan ekstraksi fitur. Hasil dari *pre-training* adalah menentukan inialisasi bobot dan bias yang akan digunakan untuk tahap *fine-tuning*. Apabila RBM sudah mencapai *layer* terakhir, *fine-tuning* dilakukan dengan *backpropagation* terhadap data latih untuk melakukan *update* bobot dan bias yang siap digunakan untuk melakukan klasifikasi.

Pada tahap klasifikasi data, data uji akan dimasukkan ke dalam DBN. DBN akan menggunakan bobot dan bias dari hasil *fine-tuning* untuk menghitung probabilitas kelas setiap data uji yang diterima. Kelas dengan probabilitas tertinggi akan dipilih sebagai kelas dari segmen sinyal EKG.

Pada tahap terakhir akan dilakukan perhitungan performansi dari hasil klasifikasi data berdasarkan target yang sebenarnya. Performansi yang akan dihitung adalah akurasi dan *f1-score*.

Data

Data yang digunakan diperoleh dari MIT-BIH *Arrhythmia Database*. Data EKG yang tersedia terdiri dari 48 rekaman. Setiap rekaman sinyal memiliki durasi selama 30 menit dan terdiri dari dua *channel*, yaitu *Modified Limb Lead II* (MLII) dan salah satu dari *Modified Lead V1*, *V2*, *V4*, atau *V5*. Masing-masing *channel* direkam melalui elektroda yang dipasangkan di sekitar dada. Frekuensi sinyal untuk masing-masing rekaman adalah 360 Hz.

Berdasarkan rekomendasi dari *Association for the Advancement of Medical Instrumentation* (AAMI), dari 48 rekaman yang tersedia, hanya 44 rekaman saja yang digunakan, dimana rekaman 102, 104, 107, dan 217 tidak digunakan karena mengandung *paced beats* (detak jantung yang diakibatkan oleh alat kejut jantung). AAMI telah memetakan 12 jenis detak jantung yang terdapat di dalam *database* MIT-BIH ke dalam empat kelas. Kelas hasil pemetaan oleh AAMI dapat dilihat di tabel berikut:

Tabel 2. Jenis EKG Berdasarkan Rekomendasi AAMI

No.	Jenis Detak Jantung MIT-BIH	Kelas Berdasarkan AAMI	Simbol
1	<i>Normal Beat</i>	Detak jantung yang bukan SVEB, VEB, ataupun <i>fusion</i>	N
2	<i>Left Bundle Branch Block Beat</i>		
3	<i>Right Bundle Branch Block Beat</i>		
4	<i>Atrial Escape Beats</i>		
5	<i>Nodal (junctional) escape beats</i>		
6	<i>Atrial Premature Beats</i>	<i>Supraventricular Ectopic Beats (SVEB)</i>	S
7	<i>Aberrated Atrial Premature Beats</i>		
8	<i>Nodal (junctional) Premature Beats</i>		
9	<i>Supraventricular Premature Beats</i>	<i>Ventricular Ectopic Beats (VEB)</i>	V
10	<i>Premature Ventricular Contraction</i>		
11	<i>Ventricular Escape Beats</i>	<i>Fusion of Ventricular and Normal Beats</i>	F
12	<i>Fusion of Ventricular and Normal Beats</i>		

Dalam Tugas Akhir ini digunakan sebanyak 6846 *sample* segmen sinyal EKG untuk melatih dan menguji sistem. Sebanyak 4092 digunakan sebagai data latih dan 2754 sisanya digunakan sebagai data uji. Dari 4092 data latih, terdapat 1522 data kelas N, 927 data kelas S, 1233 data kelas V, dan 410 data kelas F. Dari 2754 data uji, terdapat 1009 data kelas N, 657 data kelas S, 816 data kelas V, dan 272 data kelas F.

4. Evaluasi

Dalam Tugas Akhir ini terdapat tiga skenario pengujian yang dilakukan. Untuk mengetahui pengaruh variabel-variabel observasi terhadap performansi sistem, maka digunakan beberapa variabel konstan dalam setiap pengujian. Berikut adalah tabel yang menunjukkan variabel konstan untuk setiap skenario pengujian:

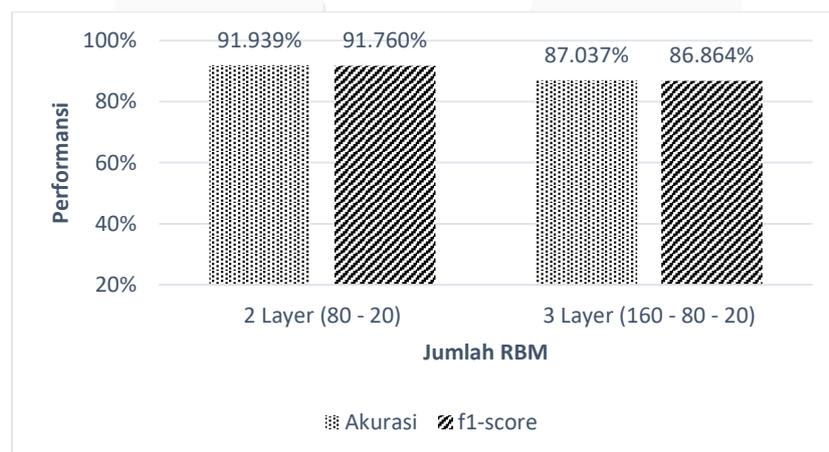
Tabel 3. Skenario Pengujian

No.	Skenario Pengujian	Variabel konstan	Nilai
1	Pengaruh jumlah RBM terhadap performansi sistem	Epoch <i>pre-training</i>	5000
		Epoch <i>fine-tuning</i>	5000
		<i>Learning rate</i>	0,5
2	Pengaruh jumlah <i>neuron</i> RBM terhadap performansi sistem	Epoch <i>pre-training</i>	5000
		Epoch <i>fine-tuning</i>	5000
		<i>Learning rate</i>	0,5
		Jumlah RBM	2
3	Pengaruh <i>learning rate</i> terhadap performansi sistem	Epoch <i>pre-training</i>	5000
		Epoch <i>fine-tuning</i>	5000
		Jumlah RBM	2
		Jumlah <i>neuron</i>	80 - 20

Hasil Pengujian

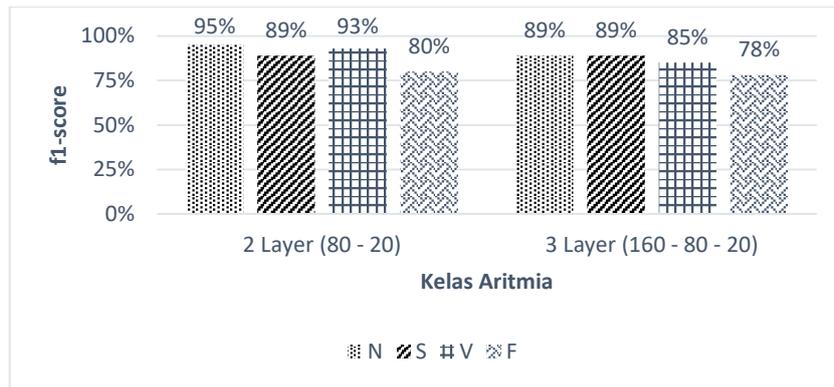
1. Pengaruh Jumlah RBM Terhadap Performansi Sistem

Berikut adalah hasil performansi untuk DBN dengan 2 RBM dan DBN dengan 3 RBM.



Gambar 3. Performansi Skenario Pertama

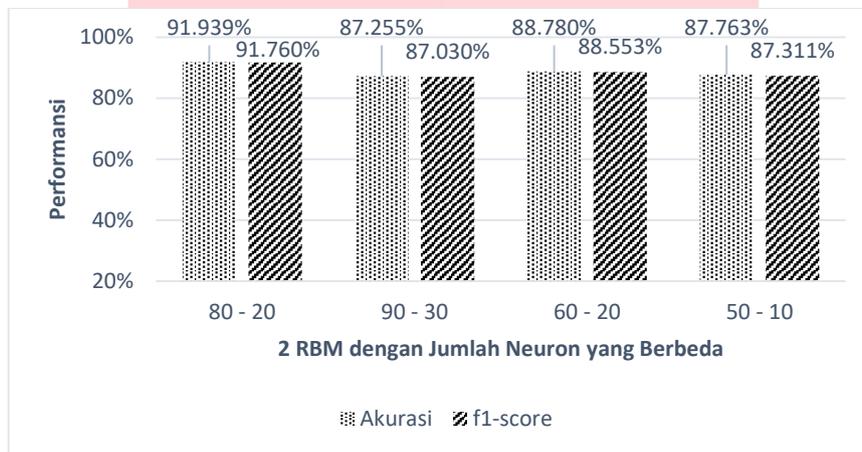
Berikut nilai *f1-score* untuk setiap kelas aritmia menggunakan DBN dengan 2 RBM dan 3 RBM.



Gambar 4. f1-score DBN 2 Layer (80 – 20) dan DBN 3 Layer (160 – 80 – 20)

2. Pengaruh Jumlah Neuron RBM Terhadap Performansi Sistem

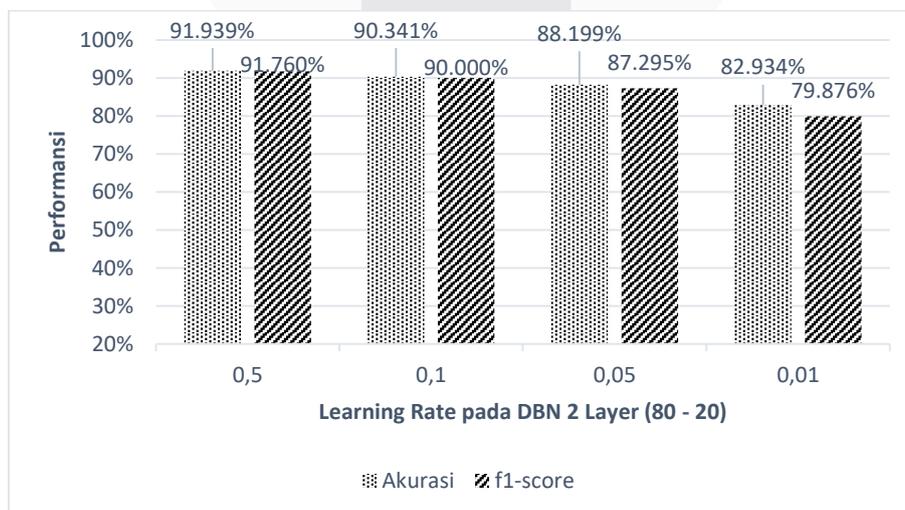
Berikut adalah hasil performansi untuk 4 jenis DBN dengan 2 RBM.



Gambar 5. Performansi Skenario Kedua

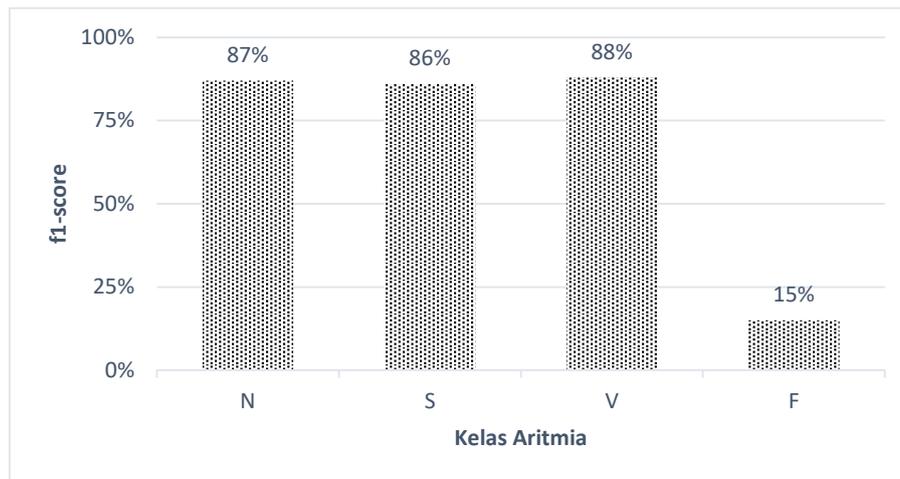
3. Pengaruh Learning Rate RBM Terhadap Performansi Sistem

Berikut adalah hasil performansi untuk DBN dengan 2 RBM menggunakan 4 nilai *learning rate* yang berbeda.



Gambar 6. Performansi Skenario Ketiga

Berikut adalah nilai *f1-score* untuk DBN dengan 2 RBM menggunakan nilai *learning rate* 0,01.



Gambar 7. f1-score DBN 2 Layer dengan Learning Rate 0,01

Analisis Hasil Pengujian

1. Pengaruh Jumlah RBM Terhadap Performansi Sistem

Gambar 2 menunjukkan bahwa performansi terbaik diperoleh saat menggunakan dua RBM. Berdasarkan gambar 2, jumlah *layer* (RBM) memberikan pengaruh yang signifikan terhadap rata-rata performansi sistem. Berdasarkan pada gambar 3, terlihat bahwa pada DBN dengan 3 RBM mengalami penurunan *f1-score* yang untuk Aritmia kelas N, V, dan F dibandingkan dengan 2 RBM.

Fungsi dari RBM adalah melakukan ekstraksi ciri, semakin banyak jumlah RBM yang digunakan maka semakin banyak proses ekstraksi ciri. Hal itu dapat menyebabkan ciri-ciri penting yang membedakan data antar kelas ikut terbuang sehingga menyebabkan turunnya performansi pada DBN dengan 3 RBM. Karena DBN dengan 2 *layer* memberikan hasil terbaik, untuk skenario-skenario selanjutnya hanya digunakan DBN dengan 2 *layer* ini untuk membandingkan parameter observasi lainnya terhadap hasil performansi sistem.

2. Pengaruh Jumlah *Neuron* RBM Terhadap Performansi Sistem

Berdasarkan gambar 4, terlihat bahwa untuk DBN dengan 2 RBM memberikan performansi terbaik dengan jumlah *neuron* 80 untuk RBM pertama dan 20 *neuron* untuk RBM kedua. Karena RBM bertugas untuk melakukan ekstraksi ciri, *neuron* di dalam RBM membaca karakteristik data *input* yang diterima. Dapat dikatakan bahwa *neuron-neuron* di dalam RBM merepresentasikan ciri khas dari data yang dibaca. Semakin banyak jumlah *neuron* berarti semakin banyak ciri yang dipertimbangkan dalam menentukan kelas dari data *input*, sebaliknya semakin sedikit jumlah *neuron* berarti semakin sedikit kemungkinan ciri yang dipertimbangkan dalam menentukan suatu kelas. Jika terlalu banyak ciri yang dipertimbangkan dalam menentukan kelas dari data *input*, performansi sistem dapat menurun karena sistem akan terlalu spesifik dalam menentukan kelas dari data *input*, sebaliknya pada saat ciri yang dipertimbangkan terlalu sedikit mengakibatkan penurunan performansi terjadi karena sistem dapat mengabaikan ciri-ciri unik yang seharusnya menjadi ciri khas suatu kelas dari data.

3. Pengaruh *Learning Rate* RBM Terhadap Performansi Sistem

Berdasarkan gambar 5 terlihat bahwa *learning rate* yang paling optimal adalah 0,5. Semakin kecil *learning rate* maka sistem akan mempelajari data semakin lambat. Hal ini dapat menyebabkan hasil pembelajaran kurang konvergen sehingga sistem tidak bisa mengenali semua jenis data dalam *epoch* yang terbatas. Terlihat pada gambar 6, saat *learning rate* 0,01, DBN masih belum bisa mengenali aritmia kelas F.

5. Kesimpulan

Kesimpulan

Berdasarkan hasil dari tiga skenario pengujian yang telah dilakukan terhadap sistem, maka dapat disimpulkan bahwa:

1. *Deep Belief Network* dapat digunakan untuk melakukan klasifikasi sinyal EKG.
2. Performansi terbaik dihasilkan dengan menggunakan DBN 2 layer yang memiliki 80 *neuron* di layer pertama dan 20 *neuron* di layer kedua.
3. Akurasi terbesar yang dapat dicapai dengan DBN 2 layer adalah 91,939% dan f1-score terbesar yang dapat dicapai adalah 91,760%.

Saran

Berikut saran yang ingin disampaikan oleh penulis untuk pengembangan Tugas Akhir ini:

1. Gunakan algoritma deteksi *r-peak* yang lebih baik dengan harapan proses segmentasi akan menghasilkan segmen sinyal yang lebih sempurna.
2. Gunakan lebih banyak *sample* saat melakukan *training* lalu gunakan *cross-validation* untuk memperoleh hasil yang lebih baik.

Daftar Pustaka

- [1] World Health Organization. (2016). *Mortality rate attributed to cardiovascular disease, cancer, diabetes or chronic respiratory disease*. Retrieved from World Health Organization: <http://www.who.int/>
- [2] Huanhuan, M., & Yue, Z. (2014). Classification of Electrocardiogram Signals with Deep Belief Networks. *IEEE 17th International Conference on Computational Science and Engineering*.
- [3] Gokhan, A., Yakup, K., & Novruz, A. (2016). A Multistage Deep Belief Networks Application on Arrhythmia Classification. *International Journal of Intelligent Systems and Applications in Engineering*.
- [4] Yan, Y., Qin, X., Wu, Y., Zhang, N., Fan, J., & Wang, L. (2015). A Restricted Boltzmann Machine Based Two-lead Electrocardiography Classification. *IEEE*.
- [5] Luo, K., Li, J., Wang, Z., & Cuschieri, A. (2017). Patient-Specific Deep Architectural Model for ECG Classification. *Journal of Healthcare Engineering*.
- [6] Wu, Z., Ding, X., & Zhang, G. (2016). A Novel Method for Classification of ECG Arrhythmias Using Deep Belief Networks. *International Journal of Computational Intelligence and Applications*.
- [7] Luz, S., E. J., Schawrtz, W. R., Camara-Chavez, G., & Menotti, D. (2015). ECG-based heartbeat classification for arrhythmia detection: A survey. *Elsevier*.
- [8] Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Elsevier*, 27–48.
- [9] Yamashita, T., Tanaka, M., Yoshida, E., Yamauchi, Y., & Fujiyoshi, H. (2014). To be Bernoulli or to be Gaussian, for a Restricted Boltzmann Machine. *International Conference on Pattern Recognition* (pp. 1520-1525). IEEE Computer Society.
- [10] Martis, R. J., Acharya, R., Mandana, L. I., Ray, & Chakraborty, C. (2012). Application of principal component analysis to ecg signals for automated diagnosis of cardiac health. *Expert Systems with Applications*.
- [11] Chazal, P. d., O'Dwyer, M., & Reilly, R. B. (2004). Automatic Classification of Heartbeats Using ECG Morphology and Heartbeat Interval Features. *IEEE Transactions on Biomedical Engineering*.