

Electrocardiogram Biometrics Recognition Menggunakan Artificial Neural Network

William Sim, Prof. Rolly Intan, Dr. Eng., Liliana, Ph.D.

Program Studi Informatika, Fakultas Teknologi Industri, Universitas Kristen Petra

Jl. Siwalankerto 121-131 Surabaya, 60236

Telp. (031) - 2983455, Fax. (031) - 8418658

E-mail: williamsim17@gmail.com, rintan@petra.ac.id, lilian@petra.ac.id

ABSTRAK

Electrocardiogram sebagai identifikasi telah banyak diteliti pada 2 dekade terakhir. Sinyal *electrocardiogram* merupakan salah satu data yang dapat digunakan dalam *biometrics recognition*. Karakteristik *electrocardiogram* yang unik pada setiap individu, mudah didapatkan, dan sulit untuk ditiru menyebabkan *electrocardiogram* cocok sebagai *biometrics recognition*. Pada penelitian ini akan dikembangkan sebuah sistem untuk mengidentifikasi subjek yang memanfaatkan sinyal *electrocardiogram*.

Penelitian ini menggunakan pendekatan *non-fiducial* pada dataset MIT-BIH Arrhythmia Database dari physionet dengan menggunakan *Artificial Neural Network* sebagai *non-sequential* klasifikator yang menawarkan kompleksitas komputasional yang lebih rendah dan tanpa memerlukan proses *feature extraction*. Pendekatan *non-fiducial* memerlukan pemotongan sinyal menjadi setiap heartbeat. Metode *Artificial Neural Network* menggunakan neuron pada setiap *layer* untuk mengklasifikasikan hasil digitalisasi sinyal *electrocardiogram*.

Hasil penelitian menunjukkan akurasi 98.886% dari model yang telah diuji menggunakan MIT-BIH Arrhythmia Database. Penelitian ini menunjukkan kemampuan *Artificial Neural Network* sebagai metode *non-sequential* untuk melakukan identifikasi *electrocardiogram* dengan pendekatan *non-fiducial*.

Kata Kunci: *Machine Learning, Artificial Neural Network, Non-fiducial, Non-sequential, Electrocardiogram*.

ABSTRACT

Research on biometrics recognition has become popular in the last two decades. Electrocardiogram signal is one among many data that can be used in biometrics recognition purposes. It is unique for each individual, easy to obtain, and hard to forge made electrocardiogram well suited for biometrics recognition. In this research, an identifier will be made using the electrocardiogram signal of each individual.

In this research, non-fiducial approach on MIT-BIH Arrhythmia Database from physionet with Artificial Neural Network as classifier was used. Non-sequential classifier offers lower computational complexity compared to sequential classifiers. Non-fiducial approach does not require feature extraction but a method of truncating the signal to each heartbeat is still required. Artificial Neural Network method uses neuron on each layer to classify digitalized electrocardiogram signal data.

Experiment result using our method achieved 98.886% accuracy using MIT-BIH Arrhythmia Database. This research demonstrates

Artificial Neural Network method capability as non-sequential classifier to identify electrocardiogram with non-fiducial approach.

Keywords: *Machine Learning, Artificial Neural Network, Non-fiducial, Non-sequential, Electrocardiogram.*

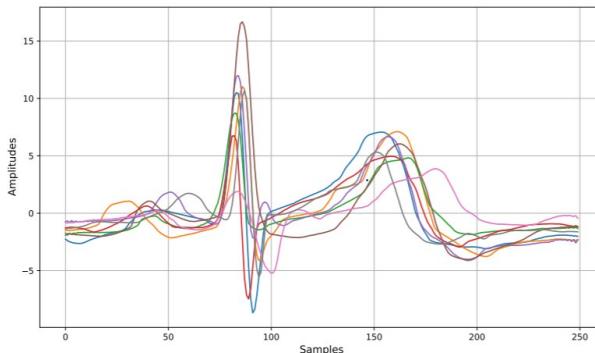
1. PENDAHULUAN

Biometric recognition adalah metode untuk mengidentifikasi manusia (mahluk hidup) secara unique menggunakan metode statistik berdasarkan physiological dan behavioural characteristics yang dimiliki subjek mahluk hidup tersebut[8, 37]. Biometrics sendiri merupakan kombinasi dari technological dan scientific authentication methods yang memanfaatkan human biology dan digunakan untuk information assurance (IA)[3]. Biometrics recognition biasanya digunakan dalam proses identifikasi dan akses kontrol atau untuk mengidentifikasi person. Saat ini, biometrics recognition yang banyak digunakan adalah dengan memanfaatkan bagian wajah[32], fingerprint[14], iris[17], dan lainnya. Namun dari semua penggunaan ini, tidak ada yang terhindar dari pencurian data maupun pemalsuan. Sebagai contoh finger mark tertinggal pada objek dan dapat dikonstruksi ulang menggunakan latex; Iris dapat diambil dari jarak beberapa meter dan mencetaknya diatas lensa kontak; dan face recognition dapat dimanipulasi menggunakan foto beresolusi tinggi. Setiap model biometric memiliki kelemahan dan keunggulan yang berbeda untuk digunakan pada kasus penggunaan yang berbeda-beda[4].

Electrocardiogram (ECG) merupakan tool untuk mengukur cardiac irregularity pada jantung yang fungsional[9, 26]. ECG bekerja dengan merekam aktivitas jantung sehingga dapat diidentifikasi apakah jantung berfungsi dengan normal atau tidak. ECG pada setiap individu bersifat unique, dan permanen berdasarkan bentuk jantung dan orientasi katup jantung untuk setiap orang[16].

Perkembangan studi mengenai penggunaan *electrocardiogram* (ECG) recording dalam *biometric recognition* meningkat pada dekade ini. ECG memiliki karakter yang *unique* seperti pada Gambar 1, dapat mendeteksi adanya kehidupan, dan sulit untuk ditiru sehingga ECG dapat digunakan untuk mengidentifikasi sebuah subjek mahluk hidup[8, 13, 24]. ECG juga membuka peluang untuk pengukuran sebuah biometrics secara terus menerus untuk memberikan data baru guna identifikasi dan memiliki akurasi yang baik meski dalam kasus yang abnormal (*low sensitivity to noise*)[30]. Keunggulan tersebut dapat digunakan dalam authentication scenario agar authentifikasi subjek tidak dapat dicuri apabila subjek sudah meninggal. *Electrocardiogram* dibandingkan dengan jenis biometrics lainnya

memiliki kelebihan tersembunyi, mudah didapatkan, dan terbukti paling menjanjikan[24].



Gambar 1. Variasi ECG dari 8 individu[25]

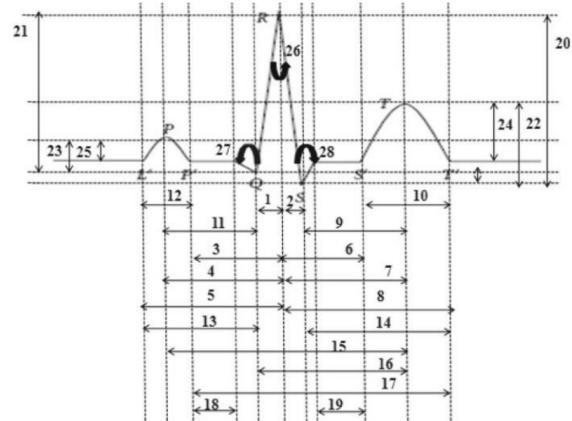
Penelitian mengenai ECG berjalan dalam 2 aspek yaitu pengambilan data yang bersangkutan dengan hardware juga metode yang digunakan untuk pengambilan data dan sisi metode recognition. Penelitian ini berjalan pada sisi mencari metode dan pendekatan yang terbaik untuk recognition. Penelitian pada sisi ini pernah dilakukan oleh Rezgui & Lachiri menggunakan metode SVM based dan mendapat akurasi 94.85% menggunakan polynomial kernel dan 98.8% menggunakan gaussian kernel, penelitian ini menggunakan fiducial approach dan mengkonjungksikan dengan *non-sequential* classifier[23]. Penelitian serupa juga pernah dilakukan oleh Patro & Kumar dengan membandingkan 3 metode ANN, SVM, K-NN dan menghasilkan performa SVM yang tertinggi dari ketiganya yaitu 93,70%, peneliti menggunakan 1 hidden layer dengan 25 node untuk konfigurasi ANN[21]. Peneliti menggunakan fiducial approach dan mengkonjungksikan dengan *non-sequential* classifier. Penelitian Lynn et al berdasarkan Recurrent Neural Network menghasilkan 98.40% pada dataset MITDB dengan menggunakan *non-fiducial* approach dan sequential classifier[16]. Sequential classifier membaca data sinyal sebagai sebuah sequence dan *non-fiducial* approach diterapkan pada penelitian ini.

Dalam penelitian ini mengkonjungksikan *non-fiducial* approach dengan mengolah data secara langsung tanpa melakukan feature extracting dan *non-sequential* classifier yang memiliki computational complexity yang lebih rendah dibandingkan sequential classifier. Penelitian ini juga akan dikembangkan model menggunakan metode *Artificial Neural Network* dengan konfigurasi hidden layer lebih dari satu hidden layer untuk mendapatkan akurasi yang lebih baik.

2. TINJAUAN STUDI

Banyak peneliti telah melakukan penelitian mengenai *electrocardiogram*(ECG) untuk digunakan sebagai biometric, biasanya berdasarkan dua pendekatan yaitu *non-fiducial*[5, 33] dan fiducial[19]. Pendekatan fiducial menerapkan *feature extraction* sebelumnya, biasanya memanfaatkan karakteristik sinyal pada daerah QRS-Complex untuk diambil menjadi fitur. Pada ECG normal, QRS-Complex mengandung P, Q, R, S, T sinyal pada setiap detak jantung(*heartbeat*). QRS-Complex menjadi *focal point* pada pendekatan ini karena pada QRS-Complex mengandung semua informasi karakteristik penting pada ECG[11]. Pendekatan *fiducial* memungkinkan untuk menciptakan fitur baru dari hasil deteksi area QRS-Complex (Gambar 2). Pendekatan *fiducial* dapat juga dikonjungksikan dengan klasifikator *non-sequential* atau yang berbasis kategorikal seperti *Multilayer*

Perceptron(MLP)[28], *Support Vector Machine*(SVM)[23], dll yang memiliki keunggulan pada sisi kompleksitas komputasi yang lebih rendah dibandingkan klasifikator sequential seperti *Recurrent Neural Network*(RNN). Namun, meskipun pendekatan ini memiliki kelebihan pada sisi tersebut, pendekatan ini cenderung sensitif terhadap *noise*, terutama pada abnormal ECG yang kemungkinan tidak memiliki semua fitur pada QRS-Complex pada ECG normal. Sehingga pendekatan *non-fiducial* disarankan dalam ECG *based recognition system*. Pendekatan *non-fiducial* tidak memanfaatkan *feature extraction* pada sinyal sebelumnya. Beberapa penulis memanfaatkan pendektoni R-peak sinyal untuk mengetahui letak detak jantung sebagai fitur utama dari ECG juga dikategorikan dalam pendekatan *non-fiducial*. Mayoritas penelitian dengan pendekatan *non-fiducial* memanfaatkan sequential klasifikator seperti model berbasis RNN[16] yang memiliki kompleksitas komputasi yang tinggi dan menyebabkan *running time* menjadi tinggi. Beberapa peneliti juga memanfaatkan *Convolutional Neural Network* untuk menganalisa hasil rekam sinyal[2, 35]. Klasifikator sequential dapat mengatasi masalah perbedaan *timeframe* detak jantung pada sinyal ECG yaitu perbedaan dimana letak sebuah detak jantung terhadap waktu terjadi. Namun klasifikator sequential memiliki kelemahan pada tingkat kompleksitas komputasi yang cenderung tinggi dibandingkan dengan *non-sequential* klasifikator.



Gambar 2. Fitur hasil generate dari QRS-Complex detection[27]

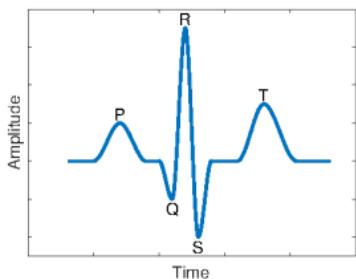
3. METODE

3.1 *Electrocardiogram*

Electrocardiogram (ECG) merupakan tool untuk mengukur cardiac irregularity pada jantung yang fungsional (Jambukia et al., 2015; Singh & Singh, 2012). *Electrocardiogram* bekerja dengan mengukur aktivitas elektrik sebuah detak jantung. Setiap satu detak jantung, sebuah impuls elektrik menempuh jantung. Berdasarkan bagian jantung yang menciptakan gelombang, gelombang dapat dibedakan menjadi:

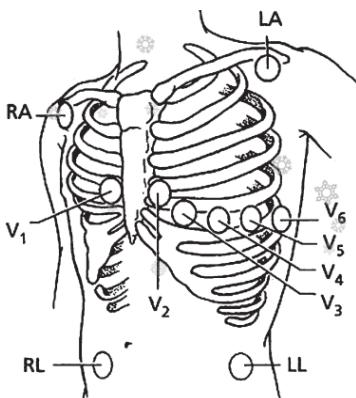
1. P Wave, merupakan gelombang yang diciptakan oleh atria kanan dan kiri atau rongga atas jantung dan kemudian diikuti garis datar ketika impuls elektrik menuju ke rongga bawah.
2. QRS Complex, merupakan gelombang yang diciptakan oleh bagian kanan dan kiri rongga bawah jantung atau ventrikel.
3. T wave, merepresentasikan return to resting state untuk ventrikel.

Komponen pada hasil rekaman *electrocardiogram* pada manusia normal yang mewakili setiap wave sebelumnya dapat dilihat pada Gambar 3.



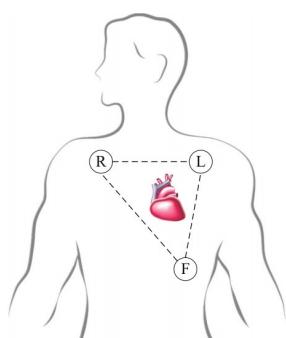
Gambar 3. Struktur komponen sinyal ECG normal[5]

Pengambilan data ECG bervariasi dalam berbagai macam. Pengambilan data ECG yang banyak ditemui pada praktik lab dan rumah sakit berbasis 12-lead ECG yang menggunakan 10 pads elektroda untuk pengambilan sinyal pada bagian tubuh pada 2 bagian chest dan limbs. Pada Gambar 4 merupakan penjelasan posisi pads elektroda berdasarkan standar American Heart Association (AHA)[6, 15, 18, 29].



Gambar 4. Model posisi penempatan elektroda 12-lead ECG[6]

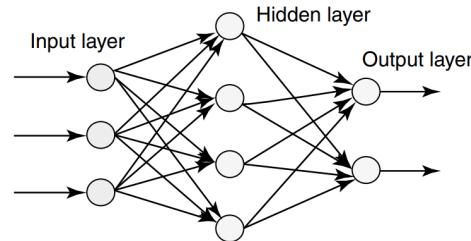
Pengambilan data ECG memerlukan subjek dalam posisi berbaring, dan dinilai kurang portabel, high-cost untuk monitoring rawat jalan maupun monitoring adanya indikasi penyakit jantung sehari-hari. Sehingga, penelitian tentang pengambilan ECG secara portabel berkembang[10, 12, 31]. Pada ECG portabel, pengambilan data memanfaatkan penempatan elektroda pada posisi menyerupai pengaturan Limb electrode pada 12-lead ECG seperti pada Gambar 5.



Gambar 5. Penempatan elektroda pada ECG portabel[31]

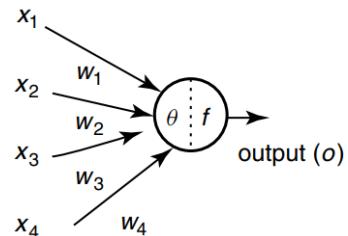
3.2 Artificial Neural Network

Artificial Neural Network (ANN) merupakan sistem komputasi yang bekerja menyerupai cara kerja biological neural network pada otak[7, 12, 20]. Struktur umum penyusun ANN terdiri dari 3 lapis/*layer* utama, yaitu input *layer*, hidden *layer*, dan output *layer* seperti penggambaran pada Gambar 6.



Gambar 6. Struktur Artificial Neural Network[1]

Artificial Neural Network mengkonjungsi banyak *artificial neuron* yang saling terkoneksi membentuk jaringan. Struktur *artificial neuron* digambarkan pada Gambar 7. Setiap *artificial neuron* mengandung *activation function* untuk memisahkan ruang input secara linear. ANN memanfaatkan kemampuan individu *artificial neuron* dan mengkonjungsi dengan *artificial neuron* lain sehingga mampu menciptakan training model yang dapat membedakan data-data yang dimasukkan. *Output* dari setiap *artificial neuron* akan dikoneksikan menjadi input *artificial neuron* lain dengan *weight* (θ) tertentu.



Gambar 7. Struktur artificial neuron[1]

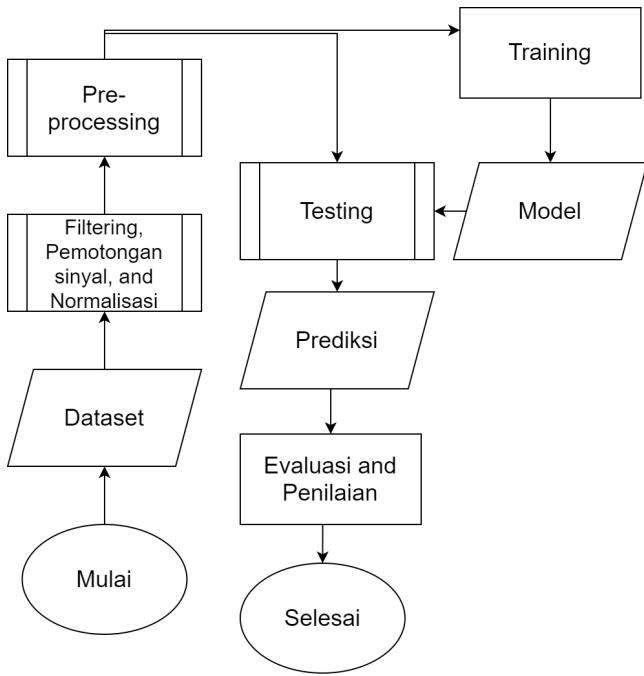
Activation function (f) merupakan fungsi yang terdapat di dalam sebuah *artificial neuron* yang digunakan untuk mengolah data input yang diterima oleh *artificial neuron* tersebut untuk dikeluarkan sebagai output. *Activation function* bertanggung jawab untuk membuat seluruh konfigurasi *Artificial Neural Network* tidak hanya sebuah fungsi linear. Pada *deep-learning* model, activation function yang sering digunakan adalah Rectified Linear Unit. ReLU atau Rectified Linear Unit biasa digunakan karena dapat mengatasi permasalahan *vanishing gradient problem* yang terjadi pada sigmoid activation function. ReLU berfungsi dengan menjadikan $x = 0$ dan $x < 0$ menjadi $x = 0$, namun dengan tetap mempertahankan nilai asli apabila $x > 0$. Fungsi ReLU didefinisikan pada persamaan (1).

$$R(z) = \max(0, z) \quad (1)$$

Multilayer Perceptron(MLP)[22] merupakan salah satu contoh konfigurasi *Artificial Neural Network*. *Multilayer Perceptron* terdiri dari satu input *layer*, lebih dari satu hidden *layer*, dan satu output *layer*. Konfigurasi *multilayer perceptron* berjalan *Feed-Forward* tanpa adanya koneksi *node* atau *artificial neuron* yang membentuk sebuah siklus dan konfigurasi pada *multilayer perceptron* merupakan *fully connected neural network*. *Multilayer perceptron* tergolong dalam kategori *supervised learning* dan mengadopsi *backpropagation* untuk proses *training*. Model *multilayer perceptron* (MLP) banyak digunakan dalam kasus klasifikasi *non-sequential* seperti klasifikasi berbasis kategori.

3.3 Desain Sistem

Pada penelitian ini, pendekatan *non-fiducial* diterapkan bersama dengan *non-sequential* klasifikator. Sistem mencangkup pengolahan sinyal, *pre-processing* data untuk *training* dan *testing*, model *Artificial Neural Network* untuk *training*, dan sistem *testing* beserta evaluasi. *Input* sistem berupa hasil rekam sinyal *electrocardiogram* yang telah diformat ulang menjadi CSV. Kemudian data akan melalui proses pemotongan, *filtering*, dan normalisasi; agar data detak jantung konsisten terhadap *timeframe* saat dimasukkan pada model *Artificial Neural Network*. Lalu data melalui proses *pre-processing* dengan membagi data untuk proses *training* dan *testing*. Data *training* digunakan untuk melatih model *Artificial Neural Network* agar dapat mengklasifikasikan subjek. Kemudian kualitas model diukur berdasarkan akurasi prediksi yang dihasilkan model dari data *testing* sebagai input prediksinya. Struktur umum sistem mulai dari *input* data hingga *output* yang digunakan dapat dilihat pada Gambar 8.

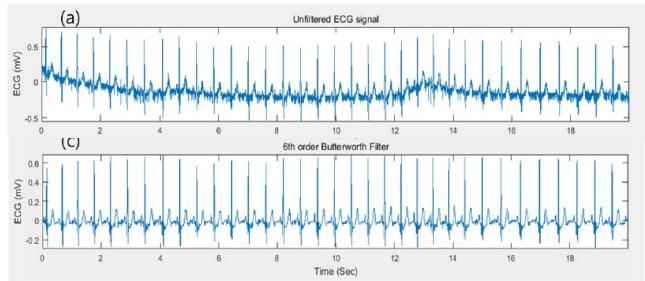


Gambar 8. Arsitektur sistem

3.3.1 Pengolahan dan Analisis Dataset

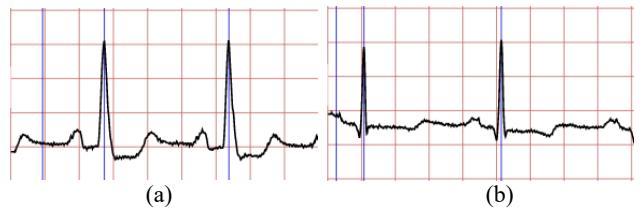
Pada bab ini membahas struktur dan konversi format yang dilakukan pada *dataset*. Pada sistem ini, data merupakan sumber informasi yang akan mempengaruhi hasil identifikasi. *Dataset* MIT-BIH mengandung 48 hasil rekam *electrocardiogram* dari 48 orang. *Dataset* berupa sinyal analog hasil rekam *single lead electrocardiogram record* dengan durasi 30 menit untuk setiap hasil rekam. Hasil rekam *electrocardiogram* diterapkan digitalisasi pada frekuensi 360hz, resolusi 11-bit, dan +10mV. Setiap row *dataset* berisi 1 rekaman hasil digitalisasi sinyal per waktu. Fitur *electrocardiogram* terdapat pada struktur sinyal di setiap denyut yang direkam. Namun pada proses perekaman ini, tidak dapat dipastikan apabila semua rekaman dimulai pada denyut yang sama (memiliki *timeframe* yang sama). *Dataset* juga memiliki *noise* yang menyebabkan setiap denyut dalam satu rekaman tidak pada skala yang sama, adanya *noise* berfrekuensi rendah akibat keringat yang mempengaruhi impedansi elektroda, pernafasan, dan pergerakan tubuh (contohnya pergerakan kecil pada elektroda)[16].

Untuk mengatasi masalah *noise*, diaplikasikan 6-th order *butterworth filter* agar dalam satu rekaman. Hasil pengaplikasian filter dapat dilihat pada Gambar 9.



Gambar 9. Hasil implementasi 6-th butterworth filter[16]

Untuk mengatasi masalah *timeframe* denyut yang berbeda seperti pada Gambar 10, sinyal dipotong menjadi per-denyut dengan *timeframe* yang sama sehingga *timeframe* denyut konsisten, dimulai pada setiap denyut dimulai.

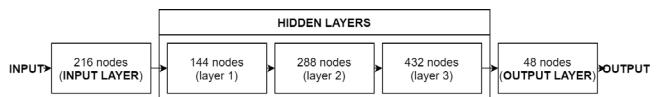


Gambar 10. Perbandingan denyut pada 2 subjek berbeda

Untuk memastikan setiap data hasil perekaman memiliki skala yang sama, diterapkan proses normalisasi pada data yang akan diproses.

3.3.2 Model

Model *Artificial Neural Network* yang digunakan dalam penelitian ini adalah *multilayer perceptron*. Model *multilayer perceptron* dilatih dengan menggunakan data *training* agar mampu mengklasifikasikan data *testing* sesuai subjek pemilik sinyal *electrocardiogram*. Arsitektur model *multilayer perceptron* yang digunakan seperti Gambar 11.



Gambar 11. Model multilayer perceptron

Model *multilayer perceptron* yang digunakan menggunakan parameter yang ditentukan sebelumnya seperti tertera pada tabel 1. *Input layer* memiliki 216 jumlah *nodes* sesuai dengan jumlah kolom pada *instance* data yang menjadi *input* pada model. Model *multilayered perceptron* dipilih karena termasuk sebagai *non-sequential* klasifikator yang menawarkan kompleksitas yang lebih rendah dibanding *sequential* klasifikator. Pada model *multilayer perceptron* ini akan dicari konfigurasi terbaik untuk menghasilkan akurasi tertinggi dengan memodifikasi kelima nilai:

1. *Hidden layers*: merupakan konfigurasi *layer* dan jumlah *nodes* per *layer* yang digunakan. Parameter ini mengatur jumlah dan formasi *hidden layer* yang digunakan
2. *Epsilon*: nilai untuk numerical stability pada adam solver.
3. *Epoch*: merupakan jumlah maksimal *epoch* untuk menjalankan proses *training*. Satu *epoch* berarti melakukan satu kali perhitungan *feed-forward* pada model yang dibuat.

Pada akhir *epoch* terjadi *weight update* yang digunakan untuk menjadi konfigurasi *epoch* berikutnya.

4. *Initial learning rate*: merupakan *learning rate* awal yang digunakan untuk inisialisasi.

5. *Activation function*: merupakan jenis *activation function* yang digunakan dalam setiap *artificial neuron* pada satu *layer* yang sama.

4. HASIL PENGUJIAN

Pengujian ini dilakukan dengan tujuan mencari konfigurasi yang menghasilkan akurasi terbaik. Pengujian dilakukan dengan menggunakan CPU, intel 9900k dengan 16 *thread* dan 16GB RAM digunakan dalam pengujian ini.

Pengujian model *Artificial Neural Network* (ANN) dilakukan dengan cara *tuning parameter* atau mengganti nilai parameter yang diinisialisasi pada model. Pada proses *training* model, parameter *solver*, *batch_size*, *early_stopping*, dan *shuffle* diatur menjadi nilai konstan seperti pada Tabel 1.

Tabel 1. Value parameter yang digunakan pada MLP

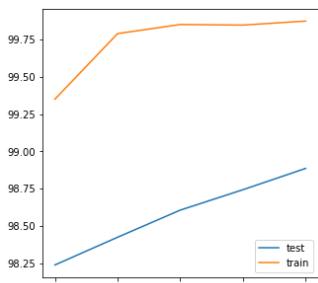
Parameters	Value
<i>Solver</i>	adam
<i>Batch_size</i>	'auto'(200)
<i>Early_stopping</i>	FALSE
<i>Shuffle</i>	FALSE

Model dinilai berdasarkan tingkat akurasi prediksi yang dihasilkan terhadap data *testing*. Parameter dimodifikasi seperti yang dijelaskan pada Bab 3.2.2. Setiap parameter yang dimodifikasi, diuji dengan kondisi parameter lainnya pada nilai konstan. Hasil pengujian yang menghasilkan nilai terbaik adalah model yang menggunakan konfigurasi pada Tabel 2.

Tabel 2. Konfigurasi parameter hasil pengujian

Parameters	Value
Jumlah <i>hidden layer</i>	3
Konfigurasi <i>hidden layer</i>	144, 288, 432
Epsilon	1e-5
<i>Initial_learning_rate</i>	0.001
<i>Activation function</i>	ReLU

Akurasi prediksi yang dicapai terhadap *epoch* atau iterasi menggunakan konfigurasi Tabel 2 dapat dilihat pada Gambar 12.



Gambar 12. Hasil akurasi prediksi terhadap epoch

Pada Gambar 12, sumbu x mewakili akurasi yang dicapai oleh model dan sumbu y mewakili jumlah *epoch* yang digunakan oleh model. Akurasi tertinggi 98.886% dicapai pada *epoch*=50.

Tabel 3. Perbandingan performa dengan model lain

Metode	Dataset	Akurasi(%)
Metode yang diusulkan	MIT-DB	98.88%
Lynn et al. [16]	MIT-DB	98.40%
Q. Zhang et al. [33]	MIT-DB	91.31%
X. Zhang et al. [34]	MIT-DB	97.82%
M. Zihlmann et al. [36]	MIT-DB	91.15%

Hasil pengujian menggunakan 80% *dataset* untuk proses *training*, komparasi dilakukan dengan model lain dengan membandingkan hasil akurasi pada pembagian yang sama yaitu 80% *dataset* untuk proses *training*. Pada Tabel 3 menunjukkan model yang diusulkan mengungguli model yang digunakan oleh Lynn et al. [16]. Sebagai tambahan, metode klasifikator yang diusulkan juga menawarkan kompleksitas komputasi yang lebih rendah secara perbandingan metode.

5. KESIMPULAN

Meskipun terhalang oleh perbedaan *timeframe* detak jantung pada setiap subjek pada *dataset*, penerapan proses pemotongan sinyal menjadi setiap detak jantung dapat menjadi solusi dan menghasilkan hasil yang memiliki akurasi tinggi. Tanpa pemotongan sinyal, klasifikator *non-sequential* tidak mampu mengklasifikasikan subjek dengan baik atau dapat dikatakan tidak mampu mengklasifikasikan subjek. Metode ini juga memiliki keunggulan dalam sensitivitas terhadap *noise* yang lebih rendah dan tidak perlu menentukan fitur yang akan digunakan untuk mengklasifikasikan subjek. Metode klasifikator ini juga unggul dalam bidang kompleksitas komputasi yang lebih rendah dibandingkan dengan sequential klasifikator sehingga tidak mengalami gejala proses *training* yang memakan waktu lama. Namun, kelemahan pada pendekatan yang diusulkan adalah jumlah fitur pada setiap *instance* yang lebih banyak karena tanpa melalui proses *feature extraction* sebelumnya. Kondisi ini mengakibatkan proses *training* cenderung lebih lama dibandingkan pada proses *training* menggunakan pendekatan fiducial tetapi dengan keunggulan tanpa melalui proses *feature extraction* sebelumnya. Hasil penelitian ini juga terbatas pada cangkupan *dataset* yang digunakan sehingga dapat dikatakan *data acquisition dependent*, penelitian terhadap variasi data yang lebih luas yang memanfaatkan bebagai macam *hardware* untuk mengambil data masih diperlukan. Kemudian, saran penelitian kedepan mencakup investigasi terhadap *dataset* yang memiliki variasi lebih luas dari sisi *hardware* yang digunakan untuk mengambil sinyal dan variasi dari sisi *electrocardiogram* yang dimiliki seseorang.

6. DAFTAR PUSTAKA

- [1] Abraham, A. 2005. *Handbook of Measuring System Design*. John Wiley & Sons, Ltd.
- [2] Acharya, U.R., Oh, S.L., Hagiwara, Y., Tan, J.H., Adam, M., Gertych, A. and Tan, R.S. 2017. A deep convolutional neural network model to classify heartbeats. *Computers in Biology and Medicine*. (2017). DOI:<https://doi.org/10.1016/j.combiomed.2017.08.022>.

- [3] Alexander, R. 2017. Using the Analytical Hierarchy Process Model in the Prioritization of Information Assurance Defense In-Depth Measures?—A Quantitative Study. *Journal of Information Security*. (2017). DOI:<https://doi.org/10.4236/jis.2017.83011>.
- [4] Canham, J. 2018. Biometrics: leap of faith or fact of life? *Biometric Technology Today*. (2018). DOI:[https://doi.org/10.1016/S0969-4765\(18\)30024-9](https://doi.org/10.1016/S0969-4765(18)30024-9).
- [5] Donida Labati, R., Muñoz, E., Piuri, V., Sassi, R. and Scotti, F. 2019. Deep-ECG: Convolutional Neural Networks for ECG biometric recognition. *Pattern Recognition Letters*. (2019). DOI:<https://doi.org/10.1016/j.patrec.2018.03.028>.
- [6] Drew, B.J., Califf, R.M., Funk, M., Kaufman, E.S., Krucoff, M.W., Laks, M.M., Macfarlane, P.W., Sommargren, C., Swiryn, S. and Van Hare, G.F. 2005. Aha scientific statement: Practice standards for electrocardiographic monitoring in hospital settings: An american heart association scientific statement from the councils on cardiovascular nursing, clinical cardiology, and cardiovascular disease in the y. *Journal of Cardiovascular Nursing*. (2005). DOI:<https://doi.org/10.1097/00005082-200503000-00003>.
- [7] Falah, F., Rahmati, O., Rostami, M., Ahmadisharaf, E., Daliakopoulos, I.N. and Pourghasemi, H.R. 2019. *Artificial Neural Networks for Flood Susceptibility Mapping in Data-Scarce Urban Areas. Spatial Modeling in GIS and R for Earth and Environmental Sciences*.
- [8] Fratini, A., Sansone, M., Bifulco, P. and Cesarelli, M. 2015. Individual identification via electrocardiogram analysis. *BioMedical Engineering Online*. 14, 1 (2015), 1–23. DOI:<https://doi.org/10.1186/s12938-015-0072-y>.
- [9] Jambukia, S.H., Dabhi, V.K. and Prajapati, H.B. 2015. Classification of ECG signals using machine learning techniques: A survey. *Conference Proceeding - 2015 International Conference on Advances in Computer Engineering and Applications, ICACEA 2015*. March (2015), 714–721. DOI:<https://doi.org/10.1109/ICACEA.2015.7164783>.
- [10] Jeon, T., Kim, B., Jeon, M. and Lee, B.G. 2014. Implementation of a portable device for real-time ECG signal analysis. *BioMedical Engineering Online*. (2014). DOI:<https://doi.org/10.1186/1475-925X-13-160>.
- [11] Karimian, N., Guo, Z., Tehranipoor, M. and Forte, D. 2017. Highly Reliable Key Generation From Electrocardiogram (ECG). *IEEE Transactions on Biomedical Engineering*. (2017). DOI:<https://doi.org/10.1109/TBME.2016.2607020>.
- [12] Kim, H., Kim, S., Van Helleputte, N., Artes, A., Konijnenburg, M., Huisken, J., Van Hoof, C. and Yazicioglu, R.F. 2014. A configurable and low-power mixed signal SoC for portable ECG monitoring applications. *IEEE Transactions on Biomedical Circuits and Systems*. (2014). DOI:<https://doi.org/10.1109/TBCAS.2013.2260159>.
- [13] Li, M. and Narayanan, S. 2010. Robust ECG biometrics by fusing temporal and cepstral information. *Proceedings - International Conference on Pattern Recognition* (2010).
- [14] Lin, C.H., Chen, J.L. and Tseng, C.Y. 2011. Optical sensor measurement and biometric-based fractal pattern classifier for fingerprint recognition. *Expert Systems with Applications*. (2011). DOI:<https://doi.org/10.1016/j.eswa.2010.09.143>.
- [15] Liu, B., Shi, G. and Zhao, W. 2017. The design of portable ECG health monitoring system. *Proceedings of the 29th Chinese Control and Decision Conference, CCDC 2017*. (2017), 2223–2226. DOI:<https://doi.org/10.1109/CCDC.2017.7978884>.
- [16] Lynn, H.M., Pan, S.B. and Kim, P. 2019. A Deep Bidirectional GRU Network Model for Biometric Electrocardiogram Classification Based on Recurrent Neural Networks. *IEEE Access*. 7, (2019), 145395–145405. DOI:<https://doi.org/10.1109/ACCESS.2019.2939947>.
- [17] Nedjah, N., Wyant, R.S., Mourelle, L.M. and Gupta, B.B. 2017. Efficient yet robust biometric iris matching on smart cards for data high security and privacy. *Future Generation Computer Systems*. (2017). DOI:<https://doi.org/10.1016/j.future.2017.05.008>.
- [18] Nelwan, S.P., Meij, S.H., van Dam, T.B. and Kors, J.A. 2001. Correction of ECG variations caused by body position changes and electrode placement during ST-T monitoring. *Journal of Electrocardiology*. (2001).
- [19] Paiva, J.S., Dias, D. and Cunha, J.P.S. 2017. Beat-ID: Towards a computationally low-cost single heartbeat biometric identity check system based on electrocardiogram wave morphology. *PLOS ONE*. (2017). DOI:<https://doi.org/10.1371/journal.pone.0180942>.
- [20] Park, Y.S. and Lek, S. 2016. *Artificial Neural Networks: Multilayer Perceptron for Ecological Modeling. Developments in Environmental Modelling*.
- [21] Patro, K.K. and Kumar, P.R. 2017. Machine learning classification approaches for biometric recognition system using ECG signals. *Journal of Engineering Science and Technology Review*. 10, 6 (2017), 1–8. DOI:<https://doi.org/10.25103/jestr.106.01>.
- [22] Ramchoun, H., Amine, M., Idrissi, J., Ghanou, Y. and Ettaouil, M. 2016. Multilayer Perceptron: Architecture Optimization and Training. *International Journal of Interactive Multimedia and Artificial Intelligence*. (2016). DOI:<https://doi.org/10.9781/ijimai.2016.415>.
- [23] Rezgui, D. and Lachiri, Z. 2016. ECG biometric recognition using SVM-based approach. *IEEJ Transactions on Electrical and Electronic Engineering*. 11, (2016), S94–S100. DOI:<https://doi.org/10.1002/tee.22241>.
- [24] Ribeiro Pinto, J., Cardoso, J.S. and Lourenco, A. 2018. Evolution, current challenges, and future possibilities in ECG Biometrics. *IEEE Access*.
- [25] Samarin, N. and Sannella, D. 2019. A key to your heart: Biometric authentication based on ECG signals. *arXiv*.
- [26] Singh, Y.N. and Singh, S.K. 2012. Evaluation of Electrocardiogram for Biometric Authentication. *Journal of Information Security*. (2012). DOI:<https://doi.org/10.4236/jis.2012.31005>.
- [27] Tang, X. and Shu, L. 2014. Classification of electrocardiogram signals with RS and quantum networks neural. *International Journal of Multimedia and Ubiquitous Engineering*. 9, 2 (2014), 363–372. DOI:<https://doi.org/10.14257/ijmue.2014.9.2.37>.
- [28] Tuerxunwaili, Nor, R.M., Rahman, A.W.B.A., Sidek, K.A. and Ibrahim, A.A. 2016. Electrocardiogram identification:

- Use a simple set of features in QRS complex to identify individuals. *Advances in Intelligent Systems and Computing* (2016).
- [29] Wagner, G.S., Macfarlane, P., Wellens, H., Josephson, M., Gorgels, A., Mirvis, D.M., Pahlm, O., Surawicz, B., Kligfield, P., Childers, R. and Gettes, L.S. 2009. AHA/ACCF/HRS Recommendations for the Standardization and Interpretation of the Electrocardiogram. *Journal of the American College of Cardiology*. (2009). DOI:<https://doi.org/10.1016/j.jacc.2008.12.016>.
- [30] Wieclaw, L., Khoma, Y., Falat, P., Sabodashko, D. and Herasymenko, V. 2017. Biometric identification from raw ECG signal using deep learning techniques. *Proceedings of the 2017 IEEE 9th International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, IDAACS 2017* (2017).
- [31] Yang, Z., Zhou, Q., Lei, L., Zheng, K. and Xiang, W. 2016. An IoT-cloud Based Wearable ECG Monitoring System for Smart Healthcare. *Journal of Medical Systems*. (2016). DOI:<https://doi.org/10.1007/s10916-016-0644-9>.
- [32] Yu, J., Sun, K., Gao, F. and Zhu, S. 2018. Face biometric quality assessment via light CNN. *Pattern Recognition Letters*. (2018).
- DOI:<https://doi.org/10.1016/j.patrec.2017.07.015>.
- [33] Zhang, Q., Zhou, D. and Zeng, X. 2017. HeartID: A Multiresolution Convolutional Neural Network for ECG-Based Biometric Human Identification in Smart Health Applications. *IEEE Access*. (2017). DOI:<https://doi.org/10.1109/ACCESS.2017.2707460>.
- [34] Zhang, X., Zhang, Y., Zhang, L., Wang, H. and Tang, J. 2019. Ballistocardiogram Based Person Identification and Authentication Using Recurrent Neural Networks. *Proceedings - 2018 11th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics, CISPBMEI 2018* (2019).
- [35] Zhao, Z., Zhang, Y., Deng, Y. and Zhang, X. 2018. ECG authentication system design incorporating a convolutional neural network and generalized S-Transformation. *Computers in Biology and Medicine*. (2018). DOI:<https://doi.org/10.1016/j.combiomed.2018.09.027>.
- [36] Zihlmann, M., Perekrestenko, D. and Tschannen, M. 2017. Convolutional recurrent neural networks for electrocardiogram classification. *Computing in Cardiology* (2017).
- [37] 2009. *Encyclopedia of Biometrics*.