

Klasifikasi Sinyal Jantung Phonocardiogram Menggunakan Metode Long Short-Term Memory (Lstm)

Miskiyanto Miskiyanto¹⁾ Jusak Jusak²⁾ Ira Puspasari³⁾

Program Studi/Jurusan Teknik Komputer
Universitas Dinamika

Jl. Raya Kedung Baruk 98 Surabaya, 60298

Email: 1)17410200044@dinamika.ac.id , 2)jusak@dinamika.ac.id, 3)ira@dinamika.ac.id

Abstrak: Jantung adalah organ vital yang digunakan dalam kegiatan sehari-hari. Namun, berdasarkan survei World Health Organization (WHO), terdapat 33% kematian disebabkan oleh Penyakit Jantung Koroner (PJK). Pemeriksaan jantung secara rutin diharapkan dapat membantu pasien dalam memonitoring kondisi jantungnya. Teknik untuk mendengarkan suara jantung dengan menggunakan elektronik atau tradisional *stethoscope*, sebuah metode lama namun sangat efektif dalam melakukan diagnosis terhadap sejumlah penyakit kardiovaskular. Namun, hasil pemeriksaan yang didasarkan pendengaran dokter, juga menjadi kendala dalam menentukan hasil pemeriksaan jantung, karena merupakan hasil subjektifitas. Hal ini menjadikan analisis pendeteksian terhadap karakteristik sinyalsuara jantung secara otomatis penting untuk dilakukan supaya tidak terjadi kesalahan diagnosa pada saat perekaman sinyal suara jantung. Dengan berkembangnya teknik klasifikasi secara otomatis dengan menggunakan *machine learning* maupun *deep learning*, telah banyak upaya yang dilakukan untuk menganalisis sinyal PCG. Dengan adanya hal tersebut, maka penulis membuat sebuah sistem untuk melakukan klasifikasi secara otomatis terhadap sinyal jantung PCG. Metode yang digunakan pada penelitian ini adalah *Long Short – Term Memory* (LSTM) dengan menggunakan variasi dataset sebanyak 3240 yang terbagi kedalam 70% data latih dan 30% data validasi. Akurasi yang didapatkan dari metode LSTM dengan menggunakan 5 hidden layer sebesar 91%. Dengan dilakukan sebanyak beberapa kali percobaan didapatkan hasil semakin banyak jumlah layer disetiap layer, maka waktu yang dibutuhkan untuk proses training data juga semakin lama.

Kata kunci: *Long Short – Term Memory, Phonocardiogram, Deep Learning*

Jantung adalah organ vital yang digunakan dalam kegiatan sehari-hari. Namun, berdasarkan survei World Health Organization (WHO), terdapat 33% kematian disebabkan oleh Penyakit Jantung Koroner (PJK) (Organization, n.d.). Pemeriksaan jantung secara rutin diharapkan dapat membantu pasien dalam memonitoring kondisi jantungnya.

Teknik untuk mendengarkan suara jantung dengan menggunakan elektronik atau tradisional *stethoscope*, sebuah metode lama namun sangat efektif dalam melakukan diagnosis terhadap sejumlah penyakit kardiovaskular. Namun, hasil pemeriksaan yang didasarkan pendengaran dokter, juga menjadi kendala dalam menentukan hasil pemeriksaan jantung, karena merupakan hasil subjektifitas. Hal ini menjadikan analisis pendeteksian terhadap karakteristik sinyal suara jantung secara otomatis penting untuk

dilakukan supaya tidak terjadi kesalahan diagnosa pada saat perekaman sinyal suara jantung.

Telah dilakukan beberapa penelitian untuk melakukan identifikasi sinyal suara jantung secara otomatis untuk dapat menentukan posisi S1 dan S2, juga murmur yang terdapat pada sinyal jantung PCG. Beberapa penelitian telah dilakukan yaitu oleh (Jusak, et al., 2020) dengan melakukan identifikasi S1 dan S2 terhadap 75 siklus sinyal jantung pada bayi normal. Durasi rata-rata T11 dan durasi rata-rata T12 dalam penelitian ini dapat digunakan sebagai acuan untuk menentukan durasi sinyal suara jantung janin normal. Pada tahun 2019 telah dilakukan sebuah penelitian untuk mengetahui letak murmur dan juga S1 dan S1 pada sebuah sistem IoT. (Puspasari, et al., 2019). Pengembangan CEMD dilakukan pada penelitian yang dilakukan oleh jusak dengan melakukan identifikasi secara semi otomatis pada sinyal suara jantung yaitu dengan metode Largest

Interval Heart Sounds Detection (LiHSD) menghasilkan nilai akurasi suara jantung normal menunjukkan 98%, sedangkan untuk anomali suara jantung sampel deteksi menghasilkan nilai akurasi mulai dari 89% hingga 97.5% (Jusak, et al., 2021).

Dengan berkembangnya teknik klasifikasi secara otomatis dengan menggunakan *machine learning* maupun *deep learning*, telah banyak upaya yang dilakukan untuk menganalisis sinyal PCG secara otomatis seperti yang dilakukan oleh Tschannen pada tahun 2016 dengan menggunakan data pada *physionet* dengan menunjukkan hasil tingkat sensitivitas, spesifisitas dan skore sebesar 96%, 83% dan 89% (M, et al., 2016). Pada penelitian yang dilakukan Chen dengan metode DNN menghasilkan tingkat akurasi sebesar 91.12% (T, et al., 2017). Kompleksitas pada sinyal jantung PCG menjadi tantangan terbesar dalam proses klasifikasi, sehingga pada tahun 2019, dilakukan sebuah penelitian segmentasi sinyal PCG (Behbani, 2019). Penelitian tersebut menunjukkan hasil yang baik, namun waktu yang digunakan dalam melakukan proses cenderung lama. Banyaknya penelitian tentang klasifikasi sinyal jantung telah dirangkum oleh Suyi Li pada tahun 2018 (Li, et al., 2020).

Long Short-Term Neural Network (LSTM) salah satu metode *machine learning* pada kategori RNN. Dengan melakukan proses masukan berupa data sekuensial. LSTM didesain untuk mempelajari data apa yang dipakai maupun yang tidak dipakai. Karena LSTM mempunyai sebuah neuron yang didalamnya memiliki gates, setiap gate berfungsi untuk mengatur memori pada setiap neuron itu sendiri. Karena LSTM melakukan proses pengolahan dengan data masukan berupa data sekuensial, maka LSTM banyak digunakan untuk pemrosesan audio, teks, video, dan data time series.

Banyaknya penelitian yang dilakukan menunjukkan bahwa klasifikasi terhadap sinyal PCG sangat penting dilakukan. Untuk itu, dengan melakukan klasifikasi sinyal jantung dengan menggunakan metode LSTM diharapkan hasil penelitian ini dapat membantu peramedis dalam melakukan identifikasi pada jantung pasien normal dan abnormal secara lebih cepat, dan memiliki akurasi yang tinggi.

LANDASAN TEORI

Jantung

Jantung organ penting dalam tubuh bekerja memompa darah, sehingga mengalir keseluruh tubuh dan mengembalikan ke jantung. Jantung terdiri dua bagian yaitu serambi (atrium)

pada bagian atas, dan bilik (ventricile) pada bagian bawah. Darah dipompa dari satu ruangan ke ruangan yang lain menggunakan otot jantung. Katup jantung membuka tiap terjadi proses pemompaan hingga darah dapat mengalir menuju ruangan yang dituju. Kemudian katup menutup dalam mencegah akirah darah yang berbalik (Maisyaroh, 2012).

Fast Fourier Transform (FFT)

Fast Fourier Transform merupakan algoritma, untuk menghitung Transformasi Fourier diskrit dengan cepat dan efisien. Banyaknya sinyal dalam sistem komunikasi yang kontinu, transformasi fourier digunakan untuk sinyal kontinu. Transformasi Fourier didefinisikan dengan rumus berikut.

$$S(f) = \int_{-\infty}^{\infty} s(t)e^{-j2\pi ft} dt$$

Dimana $s(f)$ sinyal domain frekuensi, $s(t)$ sinyal domain waktu, dan $e^{-j2\pi ft}$ konstanta sebuah sinyal, f frekuensi dan t untuk waktu.

Phonocardiogram (PCG)

Phonocardiogram (PCG) atau disebut stetoskop elektrik, adalah perangkat yang digunakan untuk mendengar suara jantung. Phonocardiogram adalah teknik menelusuri suara jantung dan merekam getaran. Melalui sebuah transduser mikrofon suara jantung direkam dan ditampilkan pada osiloskop.


Dalam mengindikasi laju dan ritme jantung saat memompa darah, dapat menggunakan suara-suara jantung yang direkam. Selain itu juga memberikan informasi tentang efektifitas pemompaan jantung, dan juga dapat memberi informasi aktifitas katup-katup jantung. Dengan ditampilkan secara visual suara jantung dapat digunakan lebih efisien oleh dokter (Debbal, 2008).

Lub-dub atau suara jantung pertama (S1) dan suara jantung kedua (S2), dihasilkan oleh suara jantung. Suara pertama (S1) dapat disebabkan oleh dua hal yaitu, penutupan katup atrioventrikular dan kontraksi otot – otot jantung. Suara yang kedua (S2) terjadi karena penutupan katup semilunaris. Jarak antara suara jantung pertama (S1) dan suara jantung (S2) memiliki selisih dimana suara jantung pertama (S1) mempunyai waktu sedikit lebih lama dibanding (S2) (Debbal, 2008). Interval diantara kedua suara sinyal jantung terdapat disebut sistole dan diastole.

Long Short-Term Memory Neural Network (LSTM)

Long Short-Term Memory Neural Network (LSTM) merupakan pengembangan dari Recurrent Neural Network (RNN), LSTM pertama kali diusulkan oleh Hochreiter dan Schmidhuber (Hochreiter & Schmidhuber, 1997) ditingkatkan oleh

Graves (Graves, 2013) LSTM diusulkan sebagai solusi untuk mengatasi terjadinya vanishing gradient pada RNN saat memproses data sequential yang panjang. Arsitektur LSTM berisi sekelompok sel memori yang terhubung secara cyclical, dan setiap unit LSTM dilengkapi dengan input gate, forget gate, dan output gate. Gate berfungsi untuk mengontrol cara keadaan internal dipertahankan atau dibuang. Struktur unit ditunjukkan pada gambar dan persamaan algoritma input ke output sel LSTM ditunjukkan sebagai berikut:



Gambar 1. Struktur LSTM

$$g^{(t)} = \sigma(b_g + U_g x^{(t)} + W_g h^{(t-1)}), \quad (1)$$

$$f^{(t)} = \sigma(b_f + U_f x^{(t)} + W_f h^{(t-1)}), \quad (2)$$

$$o^{(t)} = \sigma(b_o + U_o x^{(t)} + W_o h^{(t-1)}), \quad (3)$$

$$s^{(t)} = f^{(t)}s^{(t-1)} + g^{(t)}\sigma(b + Ux^{(t)} + Wh^{(t-1)}), \quad (4)$$

$$h^{(t)} = \tanh(s^{(t)}) o^{(t)}, \quad (5)$$

Dimana σ merepresentasikan sigmoid function dan bobot 0-1, dan $g^{(t)}$, $f^{(t)}$, $o^{(t)}$, $s^{(t)}$ merupakan input gate, forget gate, output gate, dan cell state unit. Dan b , U , dan W merupakan bisa, input weight, dan circular weight (Chung, et al., 2014).

Semua LSTM layer dikoneksikan dengan softmax function dengan rumus fungsi :

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \dots\dots\dots(6)$$

Pengujian Klasifikasi Sinyal

Akurasi, sensitivitas dan spesifikasi biasanya digunakan untuk mengukur kinerja dari sebuah metode klasifikasi pada medis. Langkah-langkah ini digunakan untuk menilai ketepatan usulan metode (Gharehbaghi, 2015), maka dilakukan perhitungan rata-rata spesifisitas (S_p) ditambah sensitivitas (S_e) sebagai berikut:

$$score = \frac{S_e + S_p}{2} \dots\dots\dots(7)$$

Dimana:

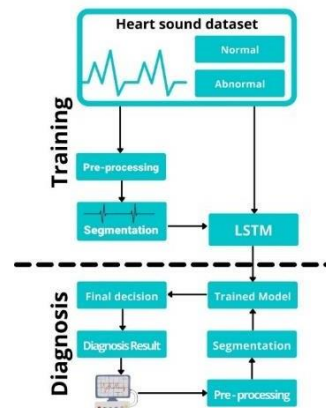
$$S_e = \frac{A_n}{A_a + A_n} \dots\dots\dots(8)$$

$$S_p = \frac{N_n}{N_a + N_n} \dots\dots\dots(9)$$

Dengan nilai A_a , N_n merepresentasikan klasifikasi abnormal dan normal bernilai benar dan A_n , N_a merepresentasikan klasifikasi abnormal dan normal bernilai salah.

METODE PENELITIAN

Perancangan klasifikasi sinyal jantung dilakukan menggunakan metode LSTM seperti yang terdapat pada gambar 4. Terdapat beberapa tahapan dalam melakukan proses klasifikasi yaitu pre processing, segmentation, dan analisis data..



Gambar 2. Perancangan kalsifikasi sinyal jantung PCG

Sinyal Normal dan Abnormal

Tahapan *pre processing* memiliki arti penting karena penggunaan stetoskop digital menyebabkan *noise* yang ikut tercampur saat proses perekaman sinyal jantung. Data yang digunakan pada proses klasifikasi memiliki beberapa klasifikasi. Data yang digunakan pada proses klasifikasi memiliki beberapa klasifikasi. Data berdasarkan suara sinyal jantung normal dan abnormal yang didapat pada database Physionet dengan topik *Classification of Normal/Abnormal Heart Sound Recordings: the PhysioNet/Computing inCardiology Challenge* tahun 2016. Data berupa sinyal jantung normal dan abnormal yang diambil dari *physionet*. Data dibagi menjadi 3 bagian dengan rasio 60%, 30% dan 10% masing-masing untuk data train, validasi dan test. Data abnormal ditandai dengan adanya murmur.

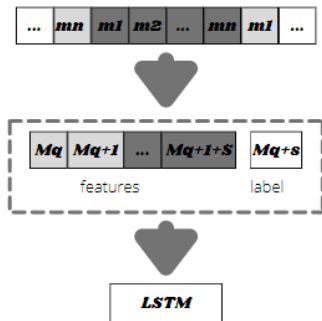
Pre-processing

Data sinyal jantung diubah dari wav menjadi *data time series* sebagai input. Sebelum dijadikan

input *neural network*, dataset terlebih dahulu di *denoising* untuk menghilangkan *noise* pada sinyal. Dengan proses *denoising* sinyal jantung yang masih memiliki *noise* dibuang dan yang yang mengandung informasi penting dipertahankan. Selain itu jika diperlukan, juga diubah frekuensi samplingnya untuk mendapatkan hasil sinyal yang mendekati sempurna setelah *training*. Input berupa nilai amplitudo terhadap waktu pada sinyal yang dikumpulkan menjadi satu dalam tabel time series, kemudian data-data tersebut disimpan dalam bentuk csv sebagai nilai inputan dari *neural network*.

Proses

Proses *training* pada jaringan LSTM diilustrasikan pada gambar 5, dilakukan dengan menjadikan tiap siklus sinyal menjadi sebuah model generatif. Setiap satu siklus sinyal PCG dilatih, dan tiap siklus menjadi fitur dalam *dataset* pelatihan. Satu siklus sinyal yang dilatihkan juga disertakan data latih label. Sinyal PCG satu siklus berpasang dengan label membentuk sebuah data yang utuh yang kemudian menjadi data untuk di ingat saat proses training menggunakan LSTM.



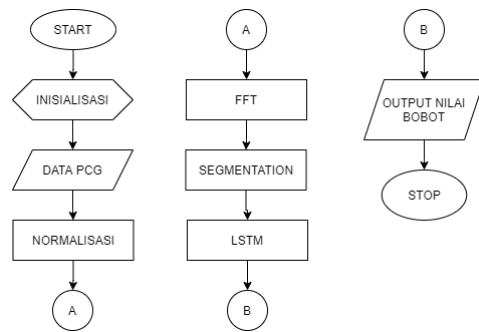
Gambar 3. Proses *training* sinyal jantung PCG

Analisis Data

Setelah dilakukan proses *training*, dilakukan proses test dengan menggunakan data test yang telah disediakan untuk melihat keberhasilan dari metode LSTM dalam melakukan klasifikasi. Parameter uji dinilai dari tingkat keberhasilan metode LSTM dalam melakukan klasifikasi data. Tingkat keberhasilan dari sebuah klasifikasi pada bidang medis dilihat dari seberapa besar tingkat akurasi, sensitifitas dan juga spesififikasi dari hasil klasifikasi. Pengukurannya dilihat dari melakukan rata-rata terhadap sensitifitas dan spesififikasi. Hasil akurasi yang diinginkan adalah diatas 80% karena dengan nilai tersebut proses klasifikasi dianggap berhasil.

Model Program

Tahapan alur program untuk *training* data dapat dilihat pada gambar 3.3 di bawah. Dimana proses *learning* dijelaskan sebagai berikut:



Gambar 4. Blok diagram program pelatihan dengan LSTM


Inisialisasi

Pada tahap ini program pertama kali menjalankan pustaka yang dibutuhkan untuk menjalankan program secara keseluruhan. Pustaka yang paling utama yaitu keras, dimana keras merupakan pustaka pada python yang banyak digunakan untuk menjalankan program *deep learning*. Kemudian juga ditambahkan pustaka numpy untuk proses aritmatika, dan pustaka sklearn untuk penghitungan nilai konvolusi matrix.

Terdapat beberapa pustaka yang digunakan untuk menjalankan program secara keseluruhan. Untuk pustaka from scipy.io import wavfile digunakan sebagai fungsi pemncaan data yang berupa audio wav. Untuk proses pelatihan menggunakan pustaka keras, sedangkan untuk operasi aritmatika menggunakan pustaka numpy.

Data PCG

Data seperti yang sudah dijelaskan pada subbab model perancangan dimana data didapat dari *Classification of Normal/Abnormal Heart Sound Recordings: the PhysioNet/Computing in Cardiology Challenge* tahun 2016. Data merupakan kumpulan suarasinyal jantung berupa wav. Berikut salah satu contoh sinyal wav yang sudah di plot.



Gambar 5. *Plotting* sinyal suara jantung PCG wav *original*


$$x_{norm} = \frac{x_{in}}{x}$$

Dimana:

x_{norm} adalah nilai sinyal suara jantung pcg yang telah dinormalisasi dan x_{in} adalah nilai masukan dari sinyal suara jantung pcg asli, x_{max} adalah nilai maksimum dari nilai sinyal suara jantung pcg. Semua nilai dari sinyal suara jantung pcg dibagi dengan nilai tertinggi dari sinyal suara jantung pcg untuk menghasilkan nilai maksimum sama dengan satu. Tujuan normalisasi adalah untuk mendapatkan nilai maksimum dari amplitudo sinyal suara jantung pcg.

Fast Fourier Transform (FFT)

Nilai FFT yang diambil merupakan nilai segmentasi dilakukan dengan membagi sinyal menjadi beberapa siklus dimana tiap siklus dibatasi menjadi 16000 data. Dengan adanya segmentasi pula sinyal yang didapat merupakan sinyal yang paling dibutuhkan dan membuang sinyal yang tidak perlu, sehingga mempercepat proses *learning*.



Gambar 6. Plot gambar sinyal FFT

Segmentasi

Segmentasi dilakukan dengan membagi sinyal menjadi beberapa siklus dimana tiap siklus dibatasi menjadi 16000 data. Dengan adanya segmentasi pula sinyal yang didapat merupakan sinyal yang paling dibutuhkan dan membuang sinyal yang tidak perlu sehingga mempercepat proses *learning*.

Modelling

Yaitu proses menyusun desain sel jaringan yang digunakan untuk nantinya dijadikan acuan model pada *learning*. Pada perancangan model memiliki struktur model yang disusun untuk memenuhi nilai bobot keluaran yang diinginkan. Untuk mengetahui keberhasilan dari model yang dibuat dapat dilihat dari nilai akurasi dan *loss*. Nilai akurasi merupakan nilai yang digunakan untuk menentukan tingkat keberhasilan model yang dibuat. Nilai *loss* adalah ukuran kesalahan jaringan, dan tujuannya adalah untuk meminimalkannya.

Nilai Bobot

Merupakan nilai acuan yang digunakan untuk mengetahui apakah memenuhi atau tidak jika nantinya data training dijadikan model untuk data prediksi. Parameter uji dinilai dari tingkat keberhasilan metode LSTM dalam melakukan klasifikasi data. Tingkat keberhasilan dari sebuah klasifikasi pada bidang medis dilihat dari seberapa besar tingkat akurasi, sensitifitas dan juga spesififikasi dari hasil klasifikasi. Pengukurannya dilihat dari melakukan rata-rata terhadap sensitifitas dan spesififikasi. Hasil akurasi yang diinginkan adalah diatas 80% karena dengan nilai tersebut proses klasifikasi dianggap berhasil. Matrik konfusi adalah bentuk matrik yang menunjukkan tingkat keberhasilan sebuah model pelatihan sinyal suara jantung pcg dalam mengklasifikasi berdasarkan dataset. Perhitungan *confusion matrix* didapat dari rumus sebagai berikut:

Tabel 1. Confusion matrix hasil klasifikasi

		1 (Positif)	0 (Negatif)
prediksi	1 (Positif)	TP (True Positif)	FN (False Negatif)
	0 (Negatif)	FN (False Negatif)	TN (True Negatif)

Untuk merepresentasikan hasil proses klasifikasi pada *confusion matrix* disimbolkan dengan 4 istilah pada tabel 1.

1. True Positif: untuk data positif yang diprediksi benar.
2. True Negatif: untuk data negatif yang diprediksi benar.
3. False Positif: untuk data negatif namun diprediksi positif.
4. False Negatif: untuk data positif namun diprediksi negatif.

HASIL DAN PEMBAHASAN

Pengujian Pelatihan Data Sinyal Suara Jantung PCG Dengan LSTM

Tujuan dari pengujian ini dilakukan untuk mengetahui proses pelatihan dapat digunakan dan berfungsi dengan baik, serta untuk mendapatkan nilai bobot sesuai dengan yang dibutuhkan dalam penelitian ini.

Tabel 2. *Data input* pelatihan


Percobaan	Input	Hidden 1	Hidden 2	Hidden 3	Hidden 4	Hidden 5
1	615	1024	2048	2048	512	512
2	615	1024	2048	2048	1024	512
3	615	1024	2048	2048	1024	1024
4	615	1024	2048	2048	2048	1024

Hasil Pengujian dengan nilai epochs 500, batch 500, input layer sebanyak 615, hidden layer pertama 1024, hidden layer kedua 2048, hidden layer ketiga 2048, hidden layer keempat 1024, dan hidden layer kelima 1024, dan berikut merupakan tabel hasil training yang diambil berdasarkan model yang telah ditentukan dapat dilihat pada tabel 2.

Tabel 3. Hasil training

No.	Epochs	Accuracy	Loss	Validasi Accuracy	Validasi Loss
1	50	0.8435	0.1147	0.9105	0.0915
2	100	0.8576	0.1037	0.9136	0.0590
3	150	0.8726	0.0976	0.8817	0.8726
4	200	0.8571	0.1081	0.8827	0.0717
5	250	0.8801	0.0887	0.9105	0.0661
6	300	0.8735	0.0931	0.8858	0.0757
7	350	0.8893	0.0824	0.9239	0.0537
8	400	0.8818	0.0846	0.9074	0.0651
9	450	0.9127	0.0676	0.9177	0.0563
10	500	0.9101	0.0674	0.8909	0.0763


Pada tabel 3 menunjukkan hasil training dari 500 epoch dimana nilai akhir dari proses tersebut berupa nilai akurasi train 0.913 dan akurasi test 0.817. Apabila proses training diatas diplot dalam sebuah grafik, maka tampilseperti yang ditunjukkan grafik dibawah.



Gambar 7. Hasil grafik percobaan

Dari grafik pada gambar 7 didapat hasil fungsi akurasi dan loss yang masih fluktuatif karena nilai akurasi training lebih tinggi daripada nilai akurasi dengan data test. Kemudian hasil akurasi test yangtelah diperoleh diolah kembali untuk mendapatkanhasil *confusion matrix*. Dengan nilai test yang didapat, maka diperoleh nilai true

positif (TP)sebanyak 121, true negatif (TN) sebanyak 125, false positif (FP) sebanyak 25, dan false negatif (FN) sebanyak 30. Jika divisualiasasi, maka diperoleh gambar 8.



Gambar 8. Confusion matrix

Dari hasil confusion matrix yang telah didapat, maka didapatkan nilai *performance matrix* yang dijadikan acuan dalam mengukur kinerja pada model yang telah dibuat. Dari model yang telah dibuat berdasarkan percobaan ketiga, maka menghasilkan *performance matrix* sebagaimana yang telah tersaji pada tabel 4 berikut.

Tabel 4. Performa matrik

	Precision	Recall	F1-Score	Support
Normal	0.81	0.83	0.82	150
Abnormal	0.83	0.80	0.81	151
Accuracy			0.82	301
Macro Avg	0.82	0.82	0.82	301
Weight Avg	0.82	0.82	0.82	301

Dari tabel 4 sesuai dengan rumus yang ditetapkan sebelumnya, maka didapatkan hasil berupa sensitivitas 82% dan spesifitas 82%. Dari nilai sensitivitas dan spesifitas dijumlahkan kemudian dibagi dua untuk mendapatkan nilai akhir berupa score. Nilai score adalah patokan kinerja model dalam memprediksi. Nilai score pada percobaan ketiga adalah 82%.

KESIMPULAN

Dari hasil pengujian klasifikasi sinyal jantung PCG menggunakan LSTM, maka didapat beberapa kesimpulan yaitu:

1. Dari data yang berupa sinyal suara jantung *phonocardiogram* berektensi wav dan melalui proses normalisasi implementasi menggunakan *long short-termmemory* dapat dijalankan.
2. Hasil akurasi model *long short-term memory* dapat dilihat dari grafik dannilai *confusion matrix*.
3. Pengujian model yang telah dibuat dengan variasi dataset sebanyak 3240 yang dibagi kedalam 70% untuk kebutuhan data latih dan 30% untuk validasi mendapatkan nilai rata-rata akurasi dari 4 kali percobaan sebesar 80% dan data *loss*

sebesar 7%.

4. Pada pengujian akurasi menggunakan model yang bervariasi nilai *hidden* layer-nya terhadap variasi proses iterasi, dengan dilakukan sebanyak 4 kali percobaan didapatkan hasil semakin banyak jumlah layer disetiap layer, maka waktu yang dibutuhkan untuk proses training data juga semakin lama.
5. Proses pengujian dengan nilai akurasi terbesar didapat dengan variasi model yang diujikan pada proses percobaan ketiga yaitu dengan nilai akhir akurasi sebanyak 91%.
6. Hasil *confusion matrix* yang didapat dari empat kali percobaan disajikan dalam bentuk visual, kemudian didapatkan hasil *performance matrix* yang disajikan dalam bentuk tabel.

DAFTAR PUSTAKA

- Behbani, S. (2019). A hybrid Algorithm fo Heart Sound Segmentation based on Phonocardioram. *Journal of Medical Engineering & Technology*, 1-15.
- Chung, J., Gulcehre, C., Cho, K., Bengio, & Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *Emprint Ervix*. Retrieved from <http://arxiv.org/abs/1412.3555v1>
- Debbal, S. M. (2008). Computerized Heart Sounds Analysis. *Computer in Biology and Medicine*, 38(2), 263-280.
- Gharehbaghi, A. B. (2015). A Novel Method for Discrimination between Innocent and Pathological Heart Murmurs. *Medical Engineering & Physics*, 37(7), 674-682.
- Graves, A. (2013). Generating Sequences with Recurrent Neural Networks. *Computation Science*.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9, 1735-1780.
- Jusak, J., Puspasari, I., & Kusumawati, W. I. (2021). A Semi-automatic Heart Sounds Identification Model and Its Implementation in Internet of Things Devices. *Advances in Electrical and Computer Engineering*, 21, 1.
- Jusak, J., Puspasari, I., Kusumawati, W. I., & Oktarina, E. S. (2020). Model Identifikasi Sinyal Jantung Pertama (S1) dan Sinyal Jantung Kedua (S2) pada Janin. *Jurnal Rekayasa Elektronika*, 16, 50-56.
- Li, S., Li, F., Tang, S., & Xiong, W. (2020). A Review of Computer-Aided Heart Sound Detection Technique. *BiomED Research International*, 2020. doi:<https://doi.org/10.1155/2020/58491>
- M, T., T, K., G, M., M, Heinzmann, & T, W. (2016). Heart sound classification using deep structured. *Computing in Cardiology Conference (CinC)*. Vancouver.
- Maisyaroh, S. (2012). *Rancang Bangun Instrumentasi Elektrokardiografi Berbasis Pc Menggunakan Sound Card*. Medan: Fakultas MIPA Jurusan S1 Fisika, Universitas Negeri Medan.
- Orgaanization, W. H. (n.d.). *Mortality Due Cardiovascular Diseases in World*. Retrieved April 15, 2020, from <https://www.medicalnewstoday.com/articles/282929>
- Puspasari, I., Jusak, J., Kusumawati, I. W., & Oktarina, E. S. (2019). A New Heart Sound Signal Identification Approach Suitabled for Smart Healthcare System. Indonesia: IEEE.
- T, C., S, Y. L., & Ho et al. (2017). S1 and S2 heart sound recognition. *IEEE Transactions on Biomedical*, 64, 372-38.