

Lung Sound Classification Using Wavelet Transformation and Recurrent Neural Networks

Moh. Muadz Ervin Yahya¹, Jondri², Achmad Rizal³

Fakultas Informatika, Universitas Telkom, Bandung

ervinyahya@student.telkomuniversity.ac.id¹, jondri@telkomuniversity.ac.id², achmadrizal@telkomuniversity.ac.id³

Abstrak

Suara paru mengacu pada bunyi spesifik yang dihasilkan oleh pergerakan udara melalui sistem pernapasan. Ada dua tipe suara paru yaitu normal dan abnormal. Contoh suara paru abnormal adalah *crackles*, *wheezes*. *Crackles* adalah suara paru yang berderak atau bergelembung yang berasal dari pangkal paru, akibat penundaan pembukaan kembali jalan napas yang menutup. *Wheezes* adalah bunyi seperti bersiul yang diakibatkan udara yang melewati jalan napas yang menutup sebagian. Pada penelitian ini, penulis membangun model klasifikasi suara paru abnormal *wheezes*, *crackles* dan suara paru normal dengan menggunakan metode wavelet haar dan wavelet daubechies 3 untuk mengekstrak vektor ciri dan menggunakan algoritma Gate Recurrent Unit (GRU) untuk mengklasifikasikan suara paru. Pada Proses klasifikasi dengan model GRU beberapa skenario pengujian ditambahkan untuk menganalisa hasil akurasi yang didapat. Hasil akurasi tertinggi didapatkan pada skenario pengujian wavelet daubechies 3, optimizer adam dan nilai dropout 0,6 mendapatkan nilai akurasi 88,81%.

Kata Kunci: *Suara paru, normal, abnormal, wavelet, GRU, akurasi*

Abstract

Lung sounds refer to the specific sounds produced by the movement of air through the respiratory system. There are two types of lung sounds, namely normal and abnormal. Examples of abnormal lung sounds are crackles, wheezes. Crackles are the sound of the lungs crackling or bubbling that originates from the base of the lungs, as a result of delays in reopening the closed airway. Wheezes are whistling sounds caused by air passing through the airway that is partially closed. In this study, the authors built a classification model for abnormal wheezes, crackles and normal lung sounds using the wavelet haar and wavelet daubechies 3 methods to extract feature vectors and using the Gate Recurrent Unit (GRU) algorithm to classify lung sounds. In the classification process with the GRU model several test scenarios are added to analyze the accuracy results obtained. The highest accuracy results were obtained in the wavelet testing scenario Daubechies 3, Adam's optimizer and the dropout value of 0,6 got an accuracy value of 88,81%.

Keywords: *Lung sounds, normal, abnormal, wavelets, GRU, accuracy*

1. Pendahuluan

Auskultasi paru adalah salah satu metode efektif untuk mendiagnosis penyakit paru. Namun, rentang frekuensi bunyi paru sekitar 100Hz hingga 2000Hz[1], sedangkan telinga manusia hanya sensitif terhadap rentang frekuensi 1000Hz hingga 2000Hz. Oleh karena itu, mudah untuk kehilangan informasi penting dari bagian frekuensi rendah bunyi paru.

Suara paru mengacu pada bunyi spesifik yang dihasilkan oleh pergerakan udara melalui sistem pernapasan. Ada dua tipe suara paru yaitu normal dan abnormal. Contoh suara paru abnormal adalah *crackles*, *wheeze*. *Crackles* adalah suara paru yang berderak atau bergelembung yang berasal dari pangkal paru, akibat penundaan pembukaan kempalin jalan napas yang menutup [2]. Adalah bunyi seperti bersiul yang diakibatkan udara yang melewati jalan napas yang menutup sebagian.

Dengan kemajuan pemrosesan sinyal digital dan teknologi kecerdasan buatan, stetoskop akustik tradisional secara bertahap diganti dengan stetoskop elektronik, yang memberikan peluang untuk menyelesaikan masalah di atas. Stetoskop elektronik dapat menyimpan sinyal suara paru dan mengirimkan sinyal suara paru ke komputer ketika dokter menggunakan stetoskop elektronik untuk mendiagnosis penyakit paru. Sinyal suara paru dapat diidentifikasi dengan menganalisis karakteristik frekuensi waktu dari sinyal dan membangun model pengenalan. Oleh karena itu, tidak hanya dapat meningkatkan akurasi diagnostik, tetapi juga meningkatkan efisiensi diagnostik dengan menggunakan teknologi kecerdasan buatan untuk menganalisis dan mengidentifikasi sinyal suara paru yang dikumpulkan oleh stetoskop elektronik.

Salah satu penelitian tentang suara paru dilakukan oleh Lukui Shi dan timnya dengan metode Wavelet dan VGGish-BiGRU[1]. Dalam penelitian tersebut, algoritma yang digunakan secara efektif meningkatkan akurasi

pengenalan suara paru, terutama akurasi asma berbeda dengan metode lain. Metode yang digunakan memiliki kemampuan generalisasi yang lebih tinggi serta lebih baik menangkap fitur temporal dari suara paru.

Pada masalah ini, penulis menggunakan algoritma *Gate Recurrent Unit* (GRU) yang merupakan salah satu model dari algoritma *Recurrent Neural Network* (RNN) untuk mengidentifikasi suara paru dan menggunakan metode Wavelet untuk mengekstraksi vektor ciri dari sinyal suara paru yang didekomposisi menjadi subband frekuensi tertentu. Dengan metode ini maka dilakukan analisis tingkat akurasi dan komputasi dalam klasifikasi suara paru.

1.1. Rumusan Masalah dan Batasannya

Berdasarkan pada latar belakang penulisan ini, terdapat perumusan masalah, yaitu:

1. Bagaimana merancang model yang dibutuhkan untuk mengklasifikasi suara paru dengan menggunakan *Gate Recurrent Unit* dan Wavelet?
2. Bagaimana pengaruh parameter pada ekstraksi ciri Wavelet dan GRU pada proses identifikasi suara paru?

Batasan yang digunakan dalam tugas akhir ini yaitu:

1. Mengklasifikasi suara paru crackles, wheeze dan normal
2. Menggunakan Wavelet diskret
3. Menggunakan RNN GRU

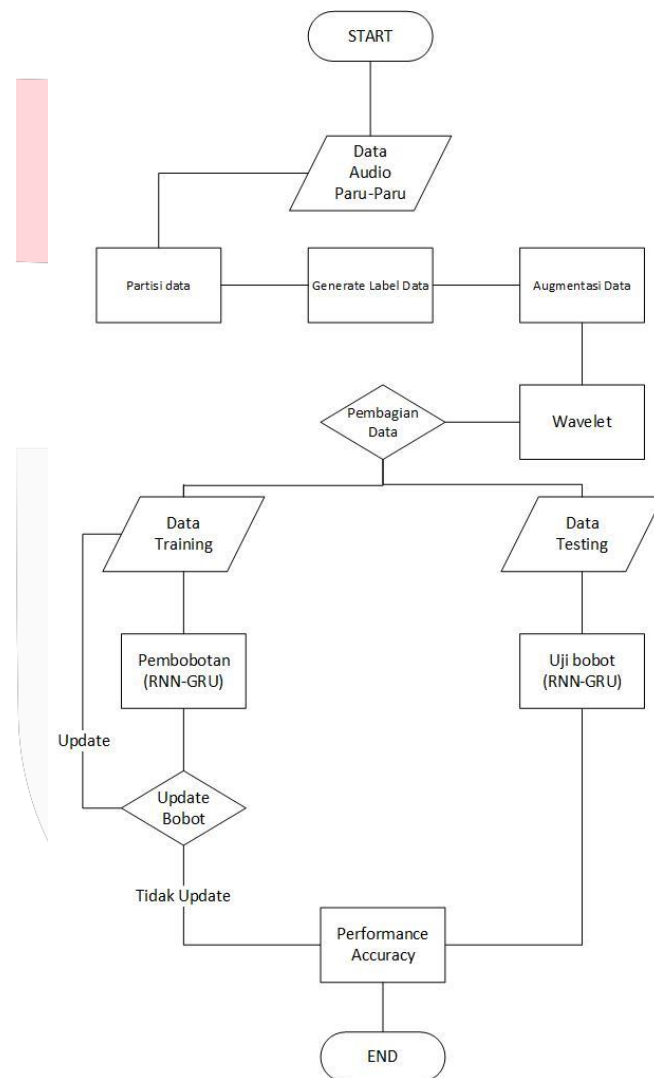
1.3. Tujuan

1. Menggunakan algoritma GRU dan wavelet untuk mengklasifikasi suara paru.
2. Melakukan klasifikasi terhadap suara paru normal, *crackles*, dan *wheeze*.
3. Mendapatkan parameter yang berpengaruh dalam proses identifikasi suara paru.

2. Studi Terkait

Salah satu penelitian tentang suara paru dilakukan oleh Lukui Shi dan timnya dengan metode Wavelet dan VGGish-BiGRU[1]. Dalam penelitian tersebut, algoritma yang digunakan secara efektif meningkatkan akurasi pengenalan suara paru, terutama akurasi asma berbeda dengan metode lain. Metode yang digunakan memiliki kemampuan generalisasi yang lebih tinggi serta lebih baik menangkap fitur temporal dari suara paru. Penelitian tersebut juga menunjukkan bahwa suara frekuensi rendah dalam suara paru lebih baik dihapus oleh penyaringan high-pass dan suara jantung dalam suara paru lebih baik dihilangkan dengan metode wavelet.

3. Sistem yang Dibangun



Gambar 1 Flowchart alur proses penelitian

3.1. Dataset

Data audio yang dipakai dalam penelitian ini adalah data dari ICBHI yang berjumlah 273 file audio. Dalam data-data tersebut ada yang tanpa gejala atau normal dan gejala abnormal berupa *crackles*, *wheeze*, dan *crackles* dengan *wheeze*. Data tersebut tidak dapat dipakai untuk menjadi dataset, sehingga akan dilakukan *preprocessing* data dengan mempartisi data tersebut dan di augmentasi. Dataset dibagi menjadi 90% data *training* dan 10% data *test*.


3.2. Partisi Data

Proses partisi data yaitu memecah data menjadi 1 siklus pernafasan yang menjadi data baru. Pemecahan tersebut akan berbeda-beda berdasarkan jumlah siklus pernafasan pada data tersebut. Data baru hasil dari partisi berjumlah 2369 data. Setelah itu data tersebut akan dilabelkan.

3.3. Augmentasi Data

Pada tahap ini bertujuan untuk menambahkan beberapa variasi dari data audio yang sudah dipartisi. Data audio akan dilakukan beberapa proses variasi data supaya sistem melakukan proses pembelajaran dengan data-data tersebut dari perspektif yang berbeda-beda sehingga meningkatkan hasil akurasi yang lebih baik. Pada Penelitian ini, variasi yang ditambahkan adalah *Noise Addition*, *Time Shifting*, *Time Stretching*, dan *Pitch Shifting*.

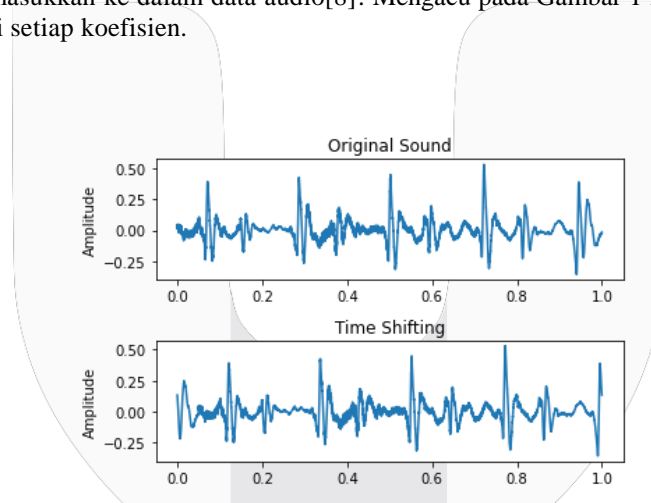
1. Noise Addition



Gambar 2 Komparasi suara original dan Noise Addition

Noise addition adalah sebuah metode untuk menambahkan *white noise*. *White noise* adalah sebuah nilai acak yang di masukkan ke dalam data audio[8]. Mengacu pada Gambar 1 Nilai yang ditambahkan antara 0 sampai 1 di setiap koefisien.


2. Time Shifting



Gambar 3 Komparasi suara original dan Time Shifting

Time Shifting adalah sebuah metode yang menghasilkan pergeseran pada sinyal tanpa mempengaruhi amplitudo dan rentang keseluruhan dari data audio tersebut. Pergeseran sinyal ini dihasilkan oleh penambahan atau pengurangan nilai waktu pada data audio tersebut. *Time Shifting* pada penelitian ini dan mengacu pada Gambar 3 menggeser waktu sebanyak 10 point.


3. Time Stretching



Gambar 4 Komparasi suara original dan Time Stretching

Time Stretching adalah metode untuk mengubah kecepatan atau durasi dari data audio tanpa merubah nada tersebut. Sehingga, dalam metode ini nada pada audio akan tetap sama dan yang dirubah hanya kecepatannya sehingga rentang durasinya saja akan berubah semakin lama. *Time Stretching* pada penelitian ini dan mengacu pada Gambar 4 melambatkan waktu pada data audio senilai 0,4.

4. Pitch Shifting



Gambar 5 Komparasi suara original dan Pitch Shifting

Time Stretching adalah kebalikan dari metode Time Stretching. Metode ini untuk mengubah nada dari data audio tanpa merubah kecepatan atau durasi dari data audio tersebut. Sehingga, dalam metode ini durasi pada audio akan tetap sama dan yang dirubah hanya nadanya. *Time Stretching pada penelitian ini* dan mengacu pada Gambar 5 menggeser nada pada data audio sebanyak 5 langkah.


3.4. Wavelet

Data audio tidak dapat langsung digunakan sebagai input dari model, karena sinyal data akan mempunyai suara noise yang akan mengganggu dalam proses ekstraksi ciri pada data dan data perlu dinormalisasi dahulu sehingga memiliki parameter yang mempunyai besaran yang sama[9]. Metode wavelet yang digunakan adalah wavelet diskrit. Wavelet akan mengekstrak koefisien wavelet yang berbeda disetiap data yang berbeda. Sinyal audio akan melewati pada rangkain filter *high-pass* dan *low-pass*, kemudian setengah dari masing-masing hasil diambil sebagai sampel melalui operasi sub-sampling. Akhirnya, koefisien akan didapatkan sebagai fitur yang akan digunakan. Wavelet diskrit yang digunakan pada penelitian ini adalah wavelet Haar dan wavelet Daubechies 3 dengan dekomposisi wavelet pada level dua. Dekomposisi wavelet memberikan perkiraan fungsi lokal dengan tingkat keteraturan pada skala yang berbeda dan dengan akurasi yang diinginkan.

$$X_{a,b} = \int_{-\infty}^{\infty} x(t) \varphi_{a,b}(t) dt \quad (1)$$

1. Haar Wavelet

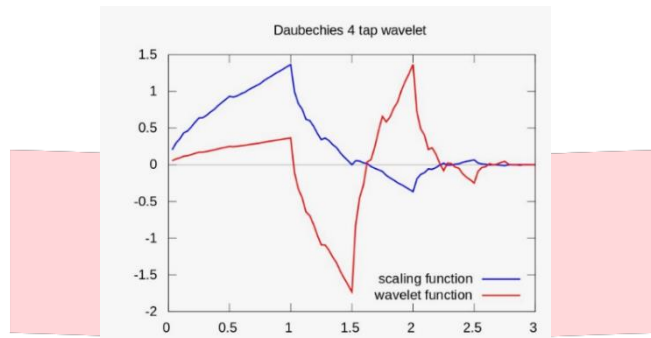
Haar Wavelet adalah teknik analisa yang mirip seperti analisa Fourier, dan merupakan wavelet pertama yang diakui secara sah. Sama seperti algoritma transformasi sebelumnya, algoritma ini akan melakukan konversi data dari bentuk spasial menjadi bentuk frekuensi, kemudian melakukan pengolahan data frekuensi, dan dikonversi menjadi bentuk spasial menggunakan inversi metode yang bersangkutan. Gambar 6 merupakan contoh hasil dari wavelet haar



Gambar 6 Contoh hasil dari wavelet haar

2. Daubechies Wavelet


Panjang tapis untuk semua keluarga daubechies adalah $dbN = 2N$, dan lebarnya $2N-1$. Untuk penulisan nama wavelet Daubechies yaitu dbN , dimana N adalah nomor indeks mengacu pada jumlah koefisien. Gambar 7 merupakan contoh hasil dari wavelet daubechies 4.



Gambar 7 Contoh hasil dari wavelet daubechies

3.5. Gate Recurrent Unit (GRU)

Gate Recurrent Unit (GRU) merupakan salah satu jenis RNN yang mirip dengan Long Short Term Memory (LSTM)[4]. Namun, dalam GRU hanya ada dua gerbang[5], reset gate(r) dan update gate(z) yang dapat dilihat pada gambar 8. Dengan demikian GRU dapat lebih menyeimbangkan hubungan antara kinerja dan kompleksitas komputasi.



Gambar 8 Gate Recurrent Unit

a. Reset Gate

Reset gate adalah gerbang yang akan menentukan berapa banyak informasi pada memori sebelumnya yang dilupakan atau dihapus. Berikut formula dari reset gate :

$$r_t = \sigma(W^{(r)}X_t + U^{(r)}h_{t-1}) \quad (4)$$

Aktivasi h_t pada waktu t adalah interpolasi linier antara aktivasi sebelumnya h_{t-1} [6]

b. Update Gate

Update gate adalah gerbang yang akan menentukan berapa banyak informasi pada memori sebelumnya yang akan disimpan dan digabungkan dengan data yang akan masuk[7].

$$z = \sigma(W^{(z)}X_t + U^{(z)}h_{t-1}) \quad (5)$$

Aktivasi h_t pada waktu t adalah interpolasi linier antara aktivasi sebelumnya h_{t-1} .

3.6 Metode Akurasi

Pada penelitian ini, untuk menghitung akurasi pada model GRU menggunakan accuracy class pada library accuracy metric pada API keras. Library accuracy metric adalah fungsi yang digunakan untuk menilai performa model pada deep learning dengan menggunakan keras. Library accuracy class ini merupakan salah satu jenis accuracy metric, library ini menghitung apakah nilai prediksi sama dengan nilai sebenarnya. Jika nilai yang dihasilkan oleh model pada penelitian ini sama dengan nilai sebenarnya maka akan dianggap akurat. Banyaknya nilai prediksi yang sama dengan nilai sebenarnya akan menentukan nilai ketepatannya atau nilai akurasinya.

4. Hasil Pengujian

Pada penelitian ini, ada beberapa Skenario pengujian dilakukan sebanyak 12 percobaan dengan beberapa parameter yang yang ditentukan. Pada setiap percobaan, model GRU akan dijalankan sebanyak 10 kali dengan *data training* dan *data test* diacak pada setiap prosesnya.

4.1. Parameter

Table 1 Hyperparameter

Parameter	Nilai
Learning rate	0,001
Loss Function	Categorical Crossentropy
Regularization method	L2 Regularization
Validation Split	0,1
Batch	64
Epoch	200

Pada tahap proses pembelajaran mesin, model GRU terdiri dari tiga hidden layers dengan 512 neuron pada lapisan pertama, 256 neuron pada lapisan kedua, dan 64 neuron pada lapisan ketiga. Ada beberapa *hyperparameter* yang ditentukan dalam setiap skenario penelitian. Tabel 1 menampilkan untuk *learning rate* bernilai 0,001 yang berpengaruh pada proses percepatan pembelajaran setiap iterasi yang dijalankan lebih cepat. *Loss function* yang digunakan yaitu *Categorical Crossentropy* yang berfungsi untuk meminimalisir kerugian pada model dan berpengaruh pada nilai bobot pada proses pembelajaran dengan lebih dari dua label data. Metode regulalisasi yang digunakan yaitu *Ridge Regression* (L2) yang berfungsi untuk untuk membatasi rentang nilai bobot pada model, sehingga mengurangi terjadinya *overfitting*. *Validation split* yang bernilai 0,1 atau 1184 data. *Batch* dan *epoch* yang ditentukan masing-masing bernilai 64 dan 200.

4.2. Skenario Pengujian

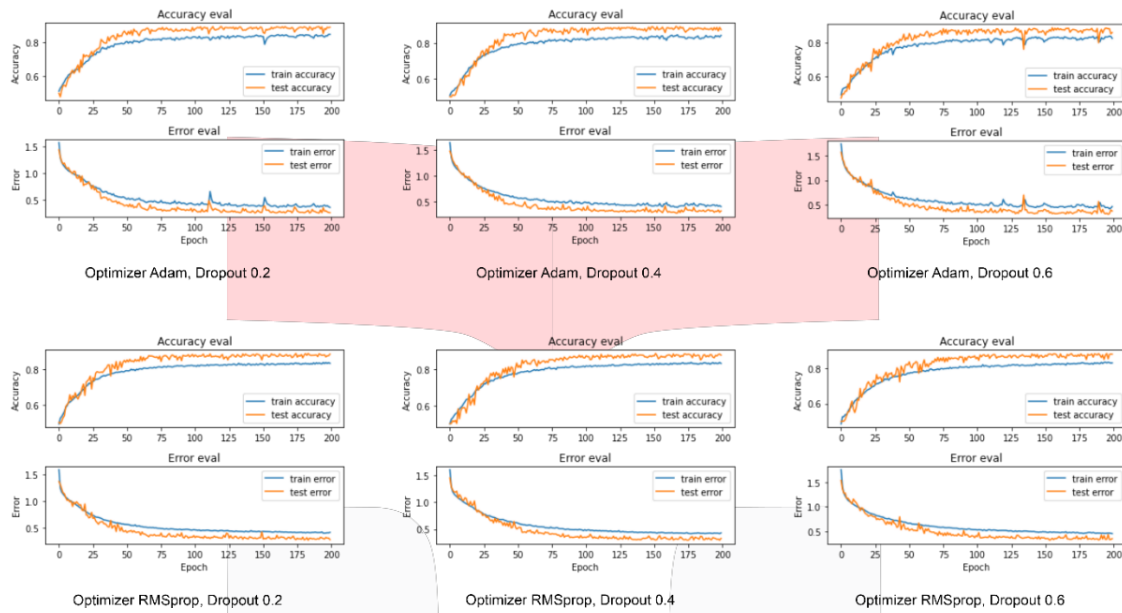
Skenario pengujian dilakukan sebanyak 12 percobaan dengan beberapa parameter yang yang ditentukan. Pada setiap percobaan, model GRU akan dijalankan sebanyak 10 kali dengan *data training* dan *data test* diacak pada setiap prosesnya.

1. Pengujian dengan Wavelet Haar

Table 2 Hasil akurasi pada Wavelet Haar

Skenario Pengujian dengan Wavelet Haar			
Optimizer	Dropout 0.2	Dropout 0.4	Dropout 0.6
Adam	0,8878	0,8751	0,8608
RMSprop	0,8835	0,8802	0,8802

Pada hasil skenario pengujian dengan wavelet Haar pada tabel 2, dapat diketahui akurasi tertinggi didapat pada saat menggunakan *optimizer* Adam dengan dropout 0,2 yang mendapatkan nilai 88,78% dan kedua dengan menggunakan *optimizer* RMSprop dengan dropout 0,2 yang bernilai 88,35%. Dari hasil pengujian ini, dua nilai akurasi terbesar didapatkan dengan *dropout* bernilai 0,2 pada dua *optimizer* tersebut. Tetapi, hasil pada saat menggunakan *optimizer* RMSprop lebih stabil dibandingkan dengan *optimizer* Adam. Hasil pengujian dengan wavelet haar dapat dilihat pada gambar 9 berikut ini.



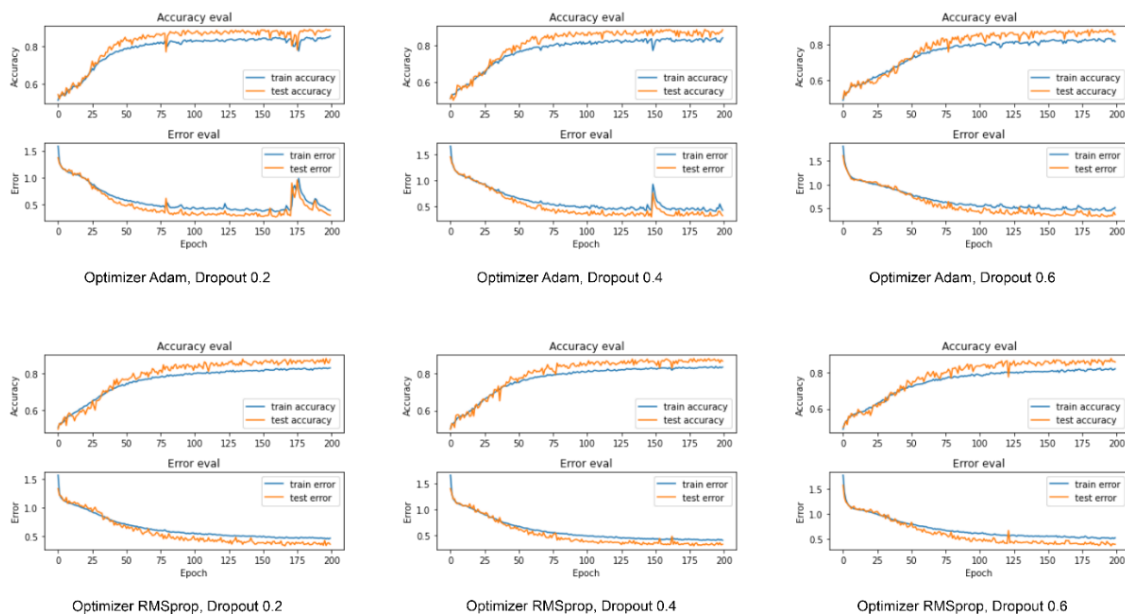
Gambar 9 Hasil pengujian dengan wavelet Haar

2. Pengujian dengan Wavelet Daubechies 3

Table 3 Hasil akurasi pada Wavelet Daubechies 3

Skenario Pengujian dengan Wavelet Daubechies 3			
Optimizer	Dropout 0.2	Dropout 0.4	Dropout 0.6
Adam	0,8867	0,8875	0,8881
RMSProp	0,8743	0,8692	0,8574

Pada skenario dengan menggunakan wavelet Daubechies 3 pada tabel 3, dapat diketahui nilai akurasi tertinggi didapat dengan *optimizer* Adam dengan *dropout* 0,6 yang mendapatkan nilai nilai 88,81% dan nilai tertinggi kedua dengan *optimizer* RMSProp dengan *dropout* 0,2 yang mendapatkan nilai nilai 87,43%. Hasil pengujian juga terlihat lebih stabil pada saat menggunakan *optimizer* Adam. Hasil dari pengujian dengan wavelet Daubechies 3, dua nilai akurasi tertinggi terjadi dengan nilai *dropout* yang berbeda tetapi pada *optimizer* yang sama, tidak seperti pada saat pengujian dengan wavelet Haar.



Gambar 10 Hasil pengujian dengan wavelet Daubechies 3

Perbedaan dalam menggunakan wavelet pada skenario pengujian mendapatkan hasil akurasi yang tidak terlalu jauh, tetapi kestabilan akurasi didapatkan pada *optimizer* yang berbeda. Hasil akurasi tertinggi didapatkan dalam pengujian dengan menggunakan wavelet Haar pada tabel 2 yang mendapat nilai akurasi 88,78% pada variasi *optimizer* Adam dan nilai *dropout* 0,2. Hasil pengujian dengan wavelet haar dapat dilihat pada gambar 10.

5. Kesimpulan dan Saran

Dalam penelitian ini, saya menggunakan dua metode dekomposisi wavelet dalam proses klasifikasi suara paru. Model recurrent neural network yang digunakan yaitu *Gate Recurrent Unit* (GRU) dengan tiga hidden layers yang memiliki 512 neuron pada lapisan pertama, 256 neuron pada lapisan kedua, dan 64 neuron pada lapisan ketiga. Hasil penelitian yang di simulasikan dalam beberapa skenario pengujian menunjukkan bahwa Hasil akurasi tertinggi pada wavelet haar didapatkan 88,78% pada *optimizer* adam dengan nilai *dropout* 0,2. Hasil akurasi tertinggi pada wavelet Daubechies 3 didapatkan 88,81% pada *optimizer* adam dengan nilai *dropout* 0,6. Menggunakan *optimizer* adam mendapatkan nilai akurasi lebih tinggi dibandingkan dengan *optimizer* rmsprop.

Dalam mengembangkan penelitian ini lebih lanjut, ada beberapa batasan yang dapat diperhatikan dalam penelitian ini. Dalam penelitian ini memiliki keterbatasan hardware yang digunakan untuk menjalankan model GRU dengan *hidden layers* dan parameter yang semakin kompleks dalam proses pengujian data, sehingga waktu yang diperlukan untuk menjalankan model akan semakin lama jika model tersebut semakin kompleks. Memaksimalkan *preprocessing* data dan pengolahan data pada metode wavelet sehingga meningkatkan nilai akurasi pada model klasifikasi.

Referensi :

- [1] L. Shi, K. Du, C. Zhang, H. Ma, and W. Yan, "Lung Sound Recognition Algorithm Based on VGGish-BiGRU," *IEEE Access*, vol. 7, pp. 139438–139449, 2019, doi: 10.1109/access.2019.2943492.
- [2] A. Rizal, R. Hidayat, and H. A. Nugroho, "Pulmonary crackle feature extraction using tsallis entropy for automatic lung sound classification," *Proc. 2016 1st Int. Conf. Biomed. Eng. Empower. Biomed. Technol. Better Futur. IBIOMED 2016*, pp. 8–11, 2017, doi: 10.1109/IBIOMED.2016.7869823.
- [3] P. M. Bentley and J. T. E. McDonnell, "Wavelet transforms : an introduction," no. August, 1994.
- [4] E. Messner *et al.*, "Crackle and Breathing Phase Detection in Lung Sounds with Deep Bidirectional Gated Recurrent Neural Networks," *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, vol. 2018-July, pp. 356–359, 2018, doi: 10.1109/EMBC.2018.8512237.
- [5] Z. Li, P. Wang, H. Lu, and J. Cheng, "Reading selectively via binary input gated recurrent unit," *IJCAI Int. Jt. Conf. Artif. Intell.*, vol. 2019-Augus, pp. 5074–5080, 2019, doi: 10.24963/ijcai.2019/705.
- [6] J. Chung, "Gated Recurrent Neural Networks on Sequence Modeling arXiv : 1412 . 3555v1 [cs . NE] 11 Dec 2014," pp. 1–9.
- [7] R. Dey and F. M. Salemt, "Gate-variants of Gated Recurrent Unit (GRU) neural networks," *Midwest Symp. Circuits Syst.*, vol. 2017-Augus, no. 2, pp. 1597–1600, 2017, doi: 10.1109/MWSCAS.2017.8053243.
- [8] R. Brand, "Microdata protection through noise addition," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 2316, pp. 97–116, 2002, doi: 10.1007/3-540-47804-3_8.
- [9] A. Rizal, R. Hidayat, and H. A. Nugroho, "Comparison of discrete wavelet transform and wavelet packet decomposition for the lung sound classification," *Far East J. Electron. Commun.*, vol. 17, no. 5, pp. 1065–1078, 2017, doi: 10.17654/EC017051065.