

Klasifikasi Suara Paru-Paru menggunakan Jaringan Syaraf Tiruan dan *Wavelet Transform*

Deny Sugiarto Wiradikusuma¹, Jondri Jondri², Achmad Rizal³

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

³School of Electrical Engineering, Telkom University, Bandung

¹denysw@student.telkomuniversity.ac.id, ²jdn@telkomuniversity.ac.id, ³ achmadrizal@telkomuniversity.ac.id

Abstraksi

Suara paru-paru merupakan salah satu data yang penting dalam dunia kesehatan untuk membantu mendeteksi penyakit pernapasan. Mendeteksi penyakit pernapasan tidak cukup hanya dengan perkiraan saja maka diperlukan juga data yang valid untuk mendapatkan hasil akurat dengan data suara paru yang di transformasi menjadi sinyal dengan menggunakan *wavelet discrete* untuk memvisualisasikan suara paru-paru serta menggunakan metode *Multilayer Perceptron* untuk mengolah data suara paru ini sehingga dapat mengklasifikasikan jenis penyakit yang diderita oleh penderita penyakit pernapasan sebesar 76% dengan lebih akurat.

Keywords: lung sound, wavelet transform, neural network, multilayer perceptron

1. Pendahuluan

Paru-paru adalah organ pernapasan manusia yang sangat penting dibutuhkan oleh manusia untuk bernapas. Dalam proses pernafasan, keluar masuknya udara dalam saluran pernafasan menghasilkan suara yang dikenal sebagai suara pernafasan atau suara paru-paru. Suara paru-paru adalah salah satu informasi penting yang dibutuhkan oleh dokter untuk menentukan tingkat kesehatan pernapasan seseorang [1]. Perubahan pola, intensitas, dan irama suara paru mengindikasikan kelainan pada saluran pernafasan, karena itu suara paru memiliki peran penting dalam penentuan kesehatan paru seseorang [2].


Banyak peneliti yang mengembangkan berbagai algoritma untuk mendiagnosis penyakit paru melalui suara paru-paru. Abbasi et.al menggunakan dekomposisi wavelet untuk mendapatkan ciri dari suara paru normal dan abnormal [3]. Neural network dan support vector machine digunakan dan dibandingkan performansinya sebagai classifier. Akurasi tertinggi mencapai 93%. Pada penelitian lain, Hjorth descriptor digunakan sebagai ciri untuk membedakan beberapa jenis suara paru [4]. Berbagai variasi scenario penggunaan Hjorth descriptor untuk klasifikasi suara paru terbukti menghasilkan akurasi yang sangat tinggi untuk lima kelas suara paru [5]. Analisis suara paru menggunakan pendekatan pengolahan sinyal wicara juga sering digunakan untuk analisis suara paru. Cepstral-Based Statistical Features terbukti menghasilkan akurasi hingga 97% untuk klasifikasi suara paru [6].

Dalam analisis sinyal biologi terkadang dibutuhkan transformasi sinyal untuk mendapatkan informasi di dalamnya. Transformasi wavelet adalah salah satu metode yang paling sering digunakan untuk analisis sinyal biologi [7], [8]. Transformasi wavelet menghasilkan akurasi yang tinggi pada beberapa penelitian terkait klasifikasi suara paru [9]–[11]. Karena transformasi wavelet menghasilkan sinyal dalam beberapa subband, masih diperlukan proses ekstraksi ciri untuk mereduksi dimensi sinyal hasil transformasi dan menguatkan perbedaan antar kelas data. Ciri yang digunakan pada subband sinyal misalnya ciri statistic (mean, variance, kurtosis, skewness) [12], Hjorth descriptor [13], dan sebagainya. Masih banyak fitur lain yang bisa dieksplorasi untuk meningkatkan akurasi klasifikasi suara paru menggunakan transformasi wavelet.

Pada penelitian ini dibahas tentang metode klasifikasi suara paru menggunakan transformasi wavelet dan multilayer perceptron. Untuk proses ekstraksi ciri, dieksplorasi beberapa ciri statistic dan time-domain features seperti mean, median, standar deviasi, root mean square (rms), variasi, percentile, dan zero-crossing. Metode yang diusulkan akan diujikan pada tiga kelas data suara paru meliputi suara paru normal, crackle, dan wheeze.

Multilayer perceptron (MLP) dipilih sebagai classifier karena strukturnya yang sederhana dan kemampuannya untuk mengenali pola, tidak sekedar jarak antar data. Metode yang diusulkan diharapkan dapat membantu dokter dalam menentukan jenis kelainan suara paru menggunakan computer.

2. Materials dan Methodologi



Gambar 1. Perancangan Sistem

Metode yang diusulkan seperti pada Gambar 1. Pada suara paru dilakukan normalisasi dan kemudian didekomposisi menggunakan DWT hingga level 5. Pada tiap subband dihitung ciri seperti mean, standar deviasi dan variance, percentile, dan zero-crossing. Ciri ini selanjutnya menjadi masukan dari MLP pada tahap klasifikasi. Detail dari tiap proses akan dijelaskan pada subsection berikut ini.

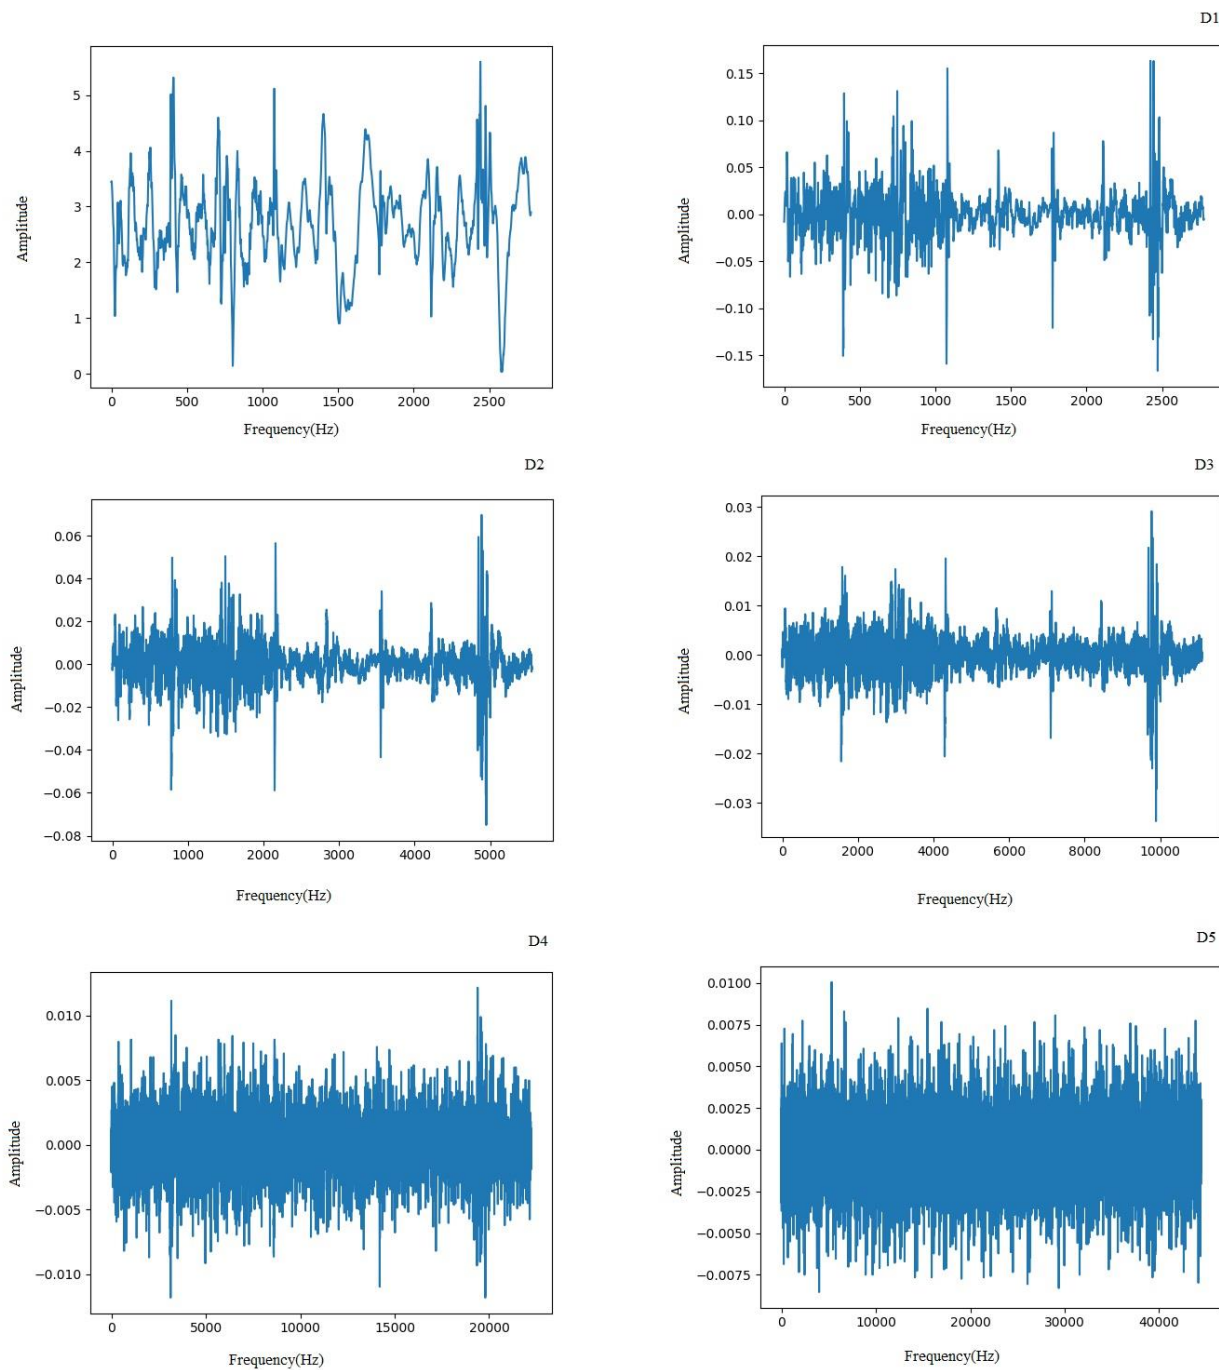
3.1 Data set suara paru-paru

Data suara paru diambil dari website International Conference on Biomedical and Health Informatics (ICBHI) 2017 (<http://bhichallenge.med.auth.gr/>) [14]. Dataset suara paru terdiri dari rekaman dari 6898 siklus pernafasan yang diambil dari 126 subjek Data set ini terdiri dari 1864 crackle, 886 wheeze, dan 506 berisi crackle dan wheeze, dengan total pajang rekaman 5.5 jam. Data suara paru ini dikumpulkan di Hospital Infante D. Pedro, Aveiro, Portugal oleh team dari School of Health Sciences, University of Aveiro (ESSUA) research team dan the Papanikolaou General Hospital, Thessaloniki and at the General Hospital of Imathia (Health Unit of Naousa), Greece oleh team dari the Aristotle University of Thessaloniki (AUTH) and the University of Coimbra (UC) [14]. Pada penelitian ini data suara paru yang digunakan berjumlah 374 data yang akan di normalisasi terlebih dahulu menjadi 2196 siklus pernafasan yang terdiri dari 1267 Normal, 635 Crackle, dan 294 Wheeze. Kelas data yang akan digunakan hanya ada 3 antara lain Normal yang akan di wakili sebagai 0, Crackle dengan 1, dan Wheeze yang akan di wakikan sebagai 2 karena untuk kelas data suara paru gabungan antara crackle dan wheeze tidak dipakai serta untuk pembagian data yang digunakan sebagai data test serta data latih pada penelitian ini digunakan sebanyak 30% dari total dataset yang ada yaitu sebanyak 659 data yang akan digunakan sebagai acuan untuk mendapatkan hasil akurasi akhir pada model. Serta dilakukan normalisasi data terlebih dahulu untuk memudahkan proses pengolahan sinyal dengan menentukan ketinggian dari amplitude antara rentang (1,-1) menggunakan proses min-max normalisasi.

3.2 Wavelet dekomposisi

Pada penelitian ini dilakukan dekomposisi wavelet level 5. Dekomposisi wavelet diskrit dinyatakan dengan persamaan;

$$DWT(j, k) = \frac{1}{\sqrt{|2^j|}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t - 2^j k}{2^j}\right) dt$$



Gambar 2. Dekomposisi wavelet

Dari data suara paru yang sudah ada dilewatkan melalui 2 filter komplementer (*Low-pass* dan *High-pass filter*) dan diperoleh pendekatan cA (Komponen frekuensi rendah) dan koefisien detail cD (Komponen frekuensi tinggi). Proses dekomposisi wavelet ini memudahkan penelitian ini untuk melihat kerapatan sinyal pada data suara paru untuk di proses ke tahap selanjutnya agar dapat dilihat perbedaan cirinya.

3.3 Fitur Ekstraksi

Pada sinyal hasil dekomposisi dilakukan proses ekstraksi ciri yang akan dijadikan masukan bagi proses klasifikasi. Ciri yang digunakan antara lain:

Entropy

$$Ent = -\sum_{n=1}^N p_i \log_2 p_i \quad (1)$$

Percentile

$$Q_i = Tb + \left[\frac{i-n-fk}{fi} \right] p \quad (2)$$

Mean

$$Mean = \frac{1}{N} \sum_{n=1}^N x \quad (3)$$

Variance dan Standar Deviasi

$$VAR = \frac{1}{N-1} \sum_{n=1}^N x_n^2 \quad (4)$$

$$STD = \sqrt{VAR} \quad (5)$$


Zero crossing

$$ZC = \sum_{n=1}^N [\text{sign}(x \times x_{n+1}) \cap |x - x_{n+1}| \geq \text{threshold}] \quad (6)$$

$$\text{sgn} = \begin{cases} 1, & \text{if } x \geq \text{threshold} \\ 0, & \text{other wise} \end{cases} \quad (7)$$

Ciri ini dihitung pada tiap subband hasil dekomposisi sehingga akan menghasilkan 72 ciri berdasarkan jenis wavelet yang dipakai yaitu 5 level.

3.4 Multilayer Perceptron



Gambar 3. *Multilayer Perceptron*


Pada penelitian ini menggunakan 5 jenis classifier MLP dengan perbedaan pada hidden layer size nya serta learning rate saja karena kemampuannya yang mampu mengolah data non-stasioner serta menggunakan 10-Fold untuk cross validation sehingga dapat meningkatkan akurasi akhir yang akan diperoleh pada saat proses validasi.

Table 1. Detail Classifier

Jenis classifier	Hidden Layer Size	Learning Rate
MLP	112,56	0.00005
MLP2	112,60	0.00005
MLP3	112,64	0.00005
MLP5	112,56	0.0001
MLP6	30,20	0.0001

Perbedaan classifier MLP yang digunakan terletak pada hidden layer size serta learning rate nya dan setiap jenis classifier memiliki tingkat akurasi yang berbeda-beda dan hasil dari pengklasifikasian menggunakan jenis classifier yang tertinggi tersebut akan digunakan untuk memvalidasi hasil akurasi akhir agar mendapatkan hasil yang lebih akurat pada model.

3. Hasil dan Diskusi




Gambar 4. Hasil dari tiap subband dari tiap kelas data: (a) Normal, (b) Crackle, (c) Wheeze

Dari hasil percobaan dengan menggunakan semua fitur ekstraksi diantaranya seperti entropy, mean, median, standar deviasi, root mean square (rms), variasi, percentile, mean-crossing, dan zero-crossing menghasilkan akurasi yang lebih tinggi karena dapat membedakan ciri pada subband nya.

Table 2. Akurasi (%) dari 6 jenis Mother Wavelet

MLP Clasifier	Mother Wavelet					
	DB1	DB3	DB8	DB19	DB25	DB28
MLP	72.7	63.6	72.7	72.7	72.7	66.6
MLP2	69.6	60.6	72.7	72.7	72.7	72.7
MLP3	72.7	57.5	60.6	54.5	63.6	63.6
MLP5	74.5	71.8	72.4	72.4	71	72.8
MLP6	72.8	70.3	69.6	68.9	68.9	69.8

Dari hasil percobaan dengan 6 jenis Mother Wavelet jenis *Daubechies1* dan classifier jenis MLP5 memiliki tingkat akurasi yang lebih tinggi diantara classifier lainnya, perbedaan classifier ditentukan oleh *hidden layer & learning rate* nya serta melakukan test terhadap wavelet yang cocok untuk di klasifikasikan oleh classifier dari dataset yang ada. Sedangkan hasil test dengan menggunakan total 374 data menunjukkan hasil akurasi tertinggi yaitu 74% ada pada classifier jenis MLP5 dengan jenis wavelet DB1 ini menunjukkan bahwa dengan menggunakan *learning rate* serta *hidden layer* yang berbeda dapat memberikan perbedaan pada hasil akurasi yang ada.



Gambar 5. Hasil validasi

Hasil validasi menggunakan jenis Mother Wavelet *Daubechies1* dan classifier MLP5 dengan *hidden layer*(112,56) menghasilkan akurasi akhir sebesar 0.7666666666666667 seperti pada gambar confusion matrix diatas.

4. Kesimpulan

Penggunaan metode MLP untuk mengklasifikasi suara paru-paru dengan menggunakan jenis Mother Wavelet *Daubechies1* menunjukkan hasil yang cukup baik setelah melewati beberapa proses normalisasi, train & test. Jadi untuk penelitian selanjutnya ada baiknya untuk mencoba menggunakan jenis classifier atau wavelet yang berbeda.

Referensi

- [1] A. Rizal, R. Hidayat, and H. A. Nugroho, "Lung sounds classification using spectrogram's first order statistics features," in *2016 6th International Annual Engineering Seminar (InAES)*, 2016, pp. 96–100.
- [2] A. Rizal, R. Hidayat, and H. A. Nugroho, "Entropy measurement as features extraction in automatic lung sound classification," in *2017 International Conference on Control, Electronics, Renewable Energy and Communications (ICCREC)*, 2017, pp. 93–97.
- [3] S. Abbasi, R. Derakhshanfar, A. Abbasi, and Y. Sarbaz, "Classification of normal and abnormal lung sounds using neural network and support vector machines," in *2013 21st Iranian Conference on Electrical Engineering (ICEE)*, 2013, pp. 1–4.
- [4] A. Rizal, R. Hidayat, and H. A. Nugroho, "Multiscale Hjorth descriptor for lung sound classification," in *AIP Conference Proceedings*, 2016, vol. 1755.
- [5] A. Rizal, R. Hidayat, and H. A. A. Nugroho, "Hjorth Descriptor Measurement on Multidistance Signal Level Difference for Lung Sound Classification," *J. Telecommun. Electron. Comput. Eng.*, vol. 9, no. 2, pp. 23–27, 2017.
- [6] N. Sengupta, M. Sahidullah, and G. Saha, "Lung sound classification using cepstral-based statistical features," *Comput. Biol. Med.*, vol. 75, pp. 118–129, Aug. 2016.
- [7] E. Koutsiana, L. J. Hadjileontiadis, I. Chouvarda, and A. H. Khandoker, "Fetal heart sounds detection using wavelet transform and fractal dimension," *Front. Bioeng. Biotechnol.*, vol. 5, no. SEP, pp. 1–9, 2017.
- [8] Y. Chen, Y. Xin, W. Hao, L. Kang, and D. Cai, "ECG quality evaluation based on wavelet multi-scale entropy," *J. Theor. Appl. Inf. Technol.*, vol. 48, no. 1, pp. 254–259, 2013.
- [9] A. Kandaswamy, C. S. Kumar, R. P. Ramanathan, S. Jayaraman, and N. Malmurugan, "Neural classification of lung sounds using wavelet coefficients.," *Comput. Biol. Med.*, vol. 34, no. 6, pp. 523–37, Sep. 2004.
- [10] A. Rizal, R. Hidayat, and H. A. Nugroho, "Multiresolution Modified Grey Level Difference for Respiratory Sound Classification," in *The 2016 Advance Research in Engineering and Information Technology International Conference (AREITIC)*, 2016, pp. 1–5.

- [11] V. I. Quandt, E. R. Pacola, S. F. Pichorim, and H. R. Gamba, "Pulmonary crackle characterization : approaches in the use of discrete wavelet transform regarding border effect , mother-wavelet selection , and subband reduction," *Res. Biomed. Eng.*, vol. 31, no. 2, pp. 148–159, 2015.
- [12] A. Hashemi, H. Arabalibiek, and K. Agin, "Classification of Wheeze Sounds Using Wavelets and Neural Networks," in *International Conference on Biomedical Engineering and Technology (2011)*, 2011, vol. 11, pp. 127–131.
- [13] A. Rizal, R. Hidayat, and H. A. Nugroho, "Lung Sound Classification Using Hjorth Descriptor Measurement on Wavelet Sub-bands," *J. Inf. Process. Syst.*, vol. 15, no. 5, pp. 2–14, 2019.
- [14] N. Maglaveras, I. Chouvarda, and P. de Carvalho, "Precision Medicine Powered by pHealth and Connected Health," vol. 66, no. November, pp. 18–21, 2018.
- [15] J. M. Nazzal, I. M. El-etary, S. a Najim, A. Ahliyya, P. O. Box, and K. S. Arabia, "Multilayer Perceptron Neural Network (MLPs) For Analyzing the Propoerties of Jordan Oil Shale," *World Appl. Sci. J.*, vol. 5, no. 5, pp. 546–552, 2008.
- [16] 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.