

Klasifikasi Suara Paru dengan Ekstraksi Ciri Wavelet Menggunakan Algoritma Stacked Denoising Autoencoder

M. Nur Hidayat W. W.¹, Jondri, S.Si., M.T², Dr. Achmad Rizal, S.T.,M.T.³

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

¹wahidwiratama@students.telkomuniversity.ac.id, ²jondri@telkomuniversity.ac.id,

³achmadrizal@telkomuniversity.ac.id

Abstrak

Paru-paru merupakan bagian terpenting bagi manusia. Paru-paru memiliki peranan penting bagi manusia dalam bernapas. Ketika orang mulai terganggu penapassannya berarti terdapat kelainan yang ada di paru-paru dan mengakibatkan terjadinya penyakit pernapasan. Kelainan dari Suara Pernapasan ini dibagi kedalam 4 kelas, yaitu kelas normal, kelas crackel, kelas wheeze, dan kelas crackel dan wheeze. Untuk mendiagnosa penyakit pernapasan ini, salah satu metodenya ialah membaca pola suara dari paru-paru menggunakan Wavelet dan *Stacked Denoising Autoencoders* (SDAE) untuk melakukan klasifikasinya. Wavelet digunakan untuk mendapat ekstraksi ciri suatu data dan SDAE digunakan untuk merekonstruksi suatu data mendekati dengan informasi data sebenarnya. Dengan menggunakan SDAE maka data dari Wavelet dapat diolah lagi menjadi data Wavelet yang bersih dan diklasifikasikan terhadap gejala-gejala pernapasan yang ada. Setelah melakukan pengujian terhadap SDAE maka didapatkan akurasi sebesar 71.57% terhadap data latih dan 67.97% terhadap data uji.

Kata kunci : Stacked Denoising Autoencoder, Wavelet

1. Pendahuluan

Latar Belakang

Perkembangan teknologi biomedik saat ini mengalami perkembangan yang begitu pesat, sehingga para dokter dapat dengan mudah menangani pasien terutama dalam mendiagnosa penyakit. Kondisi paru-paru yang sehat ditandai dengan pernapasan yang normal dan beraturan, jika tidak demikian maka bisa disimpulkan kalau kondisi paru-paru seseorang mengalami gangguan. Salah satu gangguan paling sering dialami oleh manusia adalah asma. Menurut data WHO terdapat 250.000 kematian setiap tahunnya yang disebabkan oleh asma di negara-negara yang sedang berkembang. Untuk mengetahui pernapasan seseorang adalah dengan menggunakan wavelet.

Wavelet akan mengidentifikasi sinyal pernapasan seseorang dalam bentuk gelombang. Pernapasan yang normal dapat ditandai dengan bentuk pola gelombang yang teratur. Pada umumnya dokter akan melihat data dari wavelet untuk mengidentifikasi apakah pasien terkena penyakit saluran pernapasan atau tidak. Namun belum tentu dokter akurat dalam mendiagnosa penyakit pernapasan tersebut, maka dibutuhkan bantuan mesin dalam mengidentifikasinya.

Dalam penelitian sebelumnya, Achmad Rizal dkk, pernah melakukan penelitian tentang klasifikasi suara paru dengan menggunakan fitur *spectrogram's first order statistics* dimana klasifikasinya menggunakan *K-Nearest Neighbors* (KNN). [1] Adnan Hassall, juga melakukan penelitian yang serupa. Adnan mengklasifikasikan suara paru normal dan abnormal menggunakan *Deep Neural Network* dan *Support Vector Machine* (SVM). [2] Candraditya Aridela melakukan penelitian suara paru menggunakan *Probabilistic Neural Network* (PNN) dan *Support Vector Machine* (SVM). [3]

Penelitian ini bertujuan untuk kelainan pada suara paru. Deteksi dilakukan dengan mengkonversikan data suara paru menjadi sebuah scalogram dengan menggunakan Continuous Wavelet Transform (CWT). Scalogram tersebut akan digunakan sebagai data latih Stacked Denoising Autoencoder untuk bisa dilakukan proses klasifikasi terhadap kelainan pada suara paru.

Topik dan Batasannya

Wavelet merupakan proses penggambaran gelombang yang bisa digunakan untuk dianalisis lebih lanjut tentang gelombang tersebut. Wavelet yang digunakan untuk metode ini adalah CWT untuk melihat ciri dari gelombang suara pernapasan manusia. Deep learning merupakan metode lebih dalam dalam machine learning yang memiliki daya penangkapan belajar lebih bagus dibandingkan machine learning, Deep learning ada banyak, salah satunya adalah Autoencoder. Autoencoder juga bisa dikombinasikan dengan beberapa metode seperti ditumpuk, lebih didalamnya jumlah hidden layer-nya, dan diimplementasikan dengan *Convolutional Neural Network* (CNN).

Perumusan Masalah

Perumusan masalah yang dibahas dalam penelitian ini yaitu sebagai berikut.

- Apakah SDAE bisa memiliki kinerja yang bagus pada klasifikasi suara paru?
- Bagaimana membuat model dengan memiliki kinerja yang baik untuk klasifikasi suara paru?

Tujuan

Dalam penelitian ini akan dibuktikan Stacked Denoising Autoencoder untuk melakukan proses klasifikasi suara paru dengan data yang sudah diolah dengan menggunakan CWT kedalam 4 kelas, yaitu kelas normal, kelas *crackel*, kelas *wheeze*, serta kelas *crackel* dan *wheeze*. Selain itu juga akan ditemukan performansi bagaimana akurasi dari model yang dibuat.

Organisasi Tulisan

Organisasi tulisan dalam penelitian ini yaitu sebagai berikut.

- Studi Terkait adalah bagian mengenai landasan teori yang digunakan pada penelitian.
- Sistem yang Dibangun adalah bagian mengenai prosedur pengerjaan penelitian.
- Evaluasi adalah bagian mengenai hasil dari penelitian beserta analisisnya.
- Kesimpulan adalah bagian yang berisi kesimpulan dari solusi terhadap tujuan penelitian
- Daftar Pustaka adalah bagian yang berisi sumber pustaka yang digunakan pada penelitian

2. Studi Terkait

Wavelet

Wavelet adalah metode ekstraksi ciri untuk menganalisa sinyal-sinyal non-stasioner. Dengan menggunakan wavelet, gelombang sinyal yang tidak beraturan akan dikonversikan menjadi gelombang yang lebih beraturan sehingga akan lebih mudah untuk diklasifikasi. Analisis Wavelet dapat digunakan untuk menunjukkan kelakuan sementara (temporal) dari suatu sinyal termasuk sinyal stasioner karena kemampuannya memisahkan berbagai macam karakteristik sinyal gelombang dalam berbagai skala. Wavelet sangat baik digunakan dalam menganalisa sinyal paru karena dapat mempelajari karakteristik sinyal gelombang lebih detail, sesuai dengan karakteristiknya. Klasifikasi ini akan mengelompokkan data berdasarkan kelas yang ada, diantaranya: normal, crackles, wheeze, serta crackle dan wheeze. Wavelet lebih akurat karena jendelanya lebih dinamis. Transformasi wavelet adalah dekomposisi sinyal yang telah dilatasi dan ditransilasi oleh suatu fungsi *Mother Wavelet* berikut. [4]

$$\psi_{s,t}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (1)$$


Dimana s adalah parameter dilatasi yang berbanding lurus dengan penambahan lebar dari kurva wavelet. Parameter τ adalah parameter translasi yang menunjukkan lokalisasi dari kurva wavelet dengan ruang $t=\tau$. Continuous Wavelet Transform(CWT) merupakan proses konvolusi sinyal $x(t)$ dengan sebuah fungsi window, fungsi window dapat berubah disetiap waktu dan skala yang berubah-ubah. Fungsi window merupakan mother wavelet yang menjadi fungsi dasar dari wavelet. Secara matematis CWT dari suatu signal $x(t)$ dapat di selesaikan dengan persamaan berikut. [5]

$$CWT_x^\psi(\tau, s) = \psi_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \cdot \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (2)$$

dimana s menunjukkan skala dengan nilainya berbanding terbalik dengan frekuensi, τ adalah time shift yang menunjukkan pergeseran atau translasi mother wavelet.

Skalogram

Skalogram adalah nilai absolut dari transformasi wavelet kontinu (CWT) dari suatu sinyal, yang diplot sebagai fungsi waktu dan frekuensi. Skalogram dapat lebih bermanfaat daripada spektrogram untuk menganalisis sinyal dunia nyata dengan fitur yang terjadi pada skala yang berbeda - misalnya, sinyal dengan peristiwa yang bervariasi secara perlahan diselingi oleh transien yang tiba-tiba. Berikut adalah contoh scalogram:




gambar 1: Contoh Scalogram

Sinyal akan diplot berdasarkan waktu dan frekuensi, dimana scalogram juga cocok untuk membuat gambar dari representasi sinyal non stasioner seperti suara paru.

Stacked Denoising Autoencoders


Denoising Autoencoder merupakan pengembangan dari *Autoencoder*, dengan merusak suatu data input menjadi data output yang sama dengan data input dan mendekati nilai optimal. *Autoencoder* akan mempelajari data input dan merekonstruksi data pada inputan tersebut. Didalam *Autoencoder* terdapat 2 lapisan utama yaitu *Encoder* dan *Decoder*. *Encoder* ibarat seperti memetakan data x ke data terkompresi, sedang *Decoding* data terkompresi tersebut kembali ke data $\hat{x}$ yang mendekati data inputan (asli). [6]



gambar 2: Struktur Autoencoders

Denoising Autoencoder sendiri hampir sama seperti *autoencoder* biasa hanya saja didalam *Denoising Autoencoder*, data inputan ditambahkan sebuah *noise* yang berguna untuk merusak nilai input agar nilai output lebih abstrak dan lebih bagus untuk dianalisis lebih lanjut menjadi representasi yang baik. Definisi dari representasi yang baik adalah representasi robust yang didapatkan dari input yang rusak yang berguna untuk mendapatkan input yang utuh. Inilah yang melahirkan *Denoising AutoEncoder* (DAE), DAE bertujuan untuk merekonstruksi data input yang rusak menjadi data yang utuh. [7] [8]

Stacked Denoising Autoencoder (SDAE) merupakan metode penumpukan beberapa *Denoising Autoencoder* untuk meningkatkan kemampuannya dalam melakukan abstraksi atau ekstraksi ciri. [9] Semakin tinggi level-nya semakin abstrak pula ekstraksi cirinya. Dengan menggunakan SDAE kita bisa mendapat nilai yang sebelumnya hilang menjadi nilai baru yang sepenuhnya harus ada didalam output yang kita harapkan. Proses training yang dilakukan pada tahap ini sama seperti yang dilakukan oleh DAE.



gambar 3: Struktur Stacked Denoising Autoencoder

Tahap SDAE diatas adalah penumpukan layer encoder dan decoder dengan tujuan untuk membuat daya latih autoencoder lebih baik lagi. SDAE juga bisa dikombinasikan dengan layer konvolusi untuk membuat pemrosesan gambar jauh lebih bagus lagi.

Untuk tahap penggabungan SDAE dengan layer konvolusi akan menambah beberapa layer, yaitu *convolutional* layer, maxpooling layer, upsampling layer. *Convolutional* layer adalah lapisan pokok untuk pemrosesan gambar. Pada lapis ini seluruh bidang reseptif akan ditelusuri oleh filter secara tumpang tindih parsial. Penelusuran filter secara tumpang tindih parsial menyebabkan setiap neuron akan berbagi bobot koneksi (*weight sharing*). [10]

Maxpooling layer merupakan lapisan untuk meringkas output dari setiap grup neuron pada lokasi kernel yang sama. [10] Pooling layer dilakukan untuk menjaga ukuran data ketika melakukan konvolusi dengan cara melakukan downsampling. Upsampling layer merupakan lapisan untuk melakukan kebalikan dari downsampling. Upsampling layer menggunakan algoritma *Nearest Neighbor* untuk mengembalikan gambar ke bentuk semula.

Setelah semua tahap training dilakukan dilanjutkan dengan penambahan layer output di akhir tumpukan hidden layer, serta dilakukan fine tuning untuk mereduksi error dengan pembaruan bobot pada *gradient descent*. Pada tahap akhir akan dilakukan proses *Artificial Neural Networks* (ANN). [8]

3. Sistem yang Dibangun

a. Data Preprocessing


Data yang didapat dari ICHBI berisi file audio, txt, dan hea. Data audio akan dilakukan proses denosing agar data audio akan lebih jelas. Dari data yang sudah diperoleh tadi data audio akan disamakan pemotongannya sama dengan data txt yang berisi pelabelan data dari data audio. Data yang dihasilkan berjumlah 2369 data yang terbagi menjadi kelas normal sejumlah 1251 data (52.81%), kelas crackle sejumlah 642 data (27.1%), kelas wheeze sejumlah 304 data (12.83%), dan kelas crackle and wheeze sejumlah 172 data (7.26%).

b. Augmentasi


Augmentasi data membantu menghasilkan data sintesis dari kumpulan data yang ada sehingga kemampuan generalisasi model dapat ditingkatkan. Augmentasi tujuan untuk mencegah terjadinya overfitting, dengan cara menambah varian data untuk pelatihan model. Aumentasi yang dibuat disini adalah dengan melakukan penambahan kecepatan pernapasan menjadi 2 kali lipat, mengurangi kecepatan pernapasan menjadi setengah kali lipat, dan melakukan *pitch shifting*.

c. Pengolahan sinyal ke scalogram


Data audio yang sudah dipotong akan dilakukan proses cwt sehingga data yang semula berbentuk audio akan diubah kedalam data berupa gambar representasi dari cwt. Data dari .txt juga akan diproses sehingga pelabelan terhadap 1 siklus respirasi seseorang. Berikut adalah gambar scalogram terhadap kelas ciri dari paru-paru:




gambar 4: Scalogram Kelas Normal



gambar 5: Scalogram Kelas crackle



gambar 6: Scalogram Kelas wheeze



gambar 4: Scalogram Kelas crackle dan wheeze

Kelas normal ditunjukkan dengan gelombang suara paru yang stabil dari awal siklus hingga akhir siklus. Kelas *crackel* ditunjukkan dengan gelombang suara paru yang kurang stabil, gambar per gelombang tidak stabil dan sedikit berjauhan. Kelas *wheeze* ditunjukkan dengan gelombang suara paru yang bertumpuk di awal atau akhir siklus. Kelas *crackel* dan *wheeze* merupakan gabungan dari gejala kelas *crackel* dan *wheeze*.

d. Pembagian data

Data yang sudah diolah akan dibagi menjadi 3 yaitu data train, data validasi, data test. Untuk data train dan validasi akan dilakukan proses cross validasi agar didapatkan model yang konsisten.

e. Pembuatan Model SDAE

Model SDAE yang akan dibentuk adalah model *autoencoder* yang ditumpuk sehingga menghasilkan *stacking autoencoder*, untuk proses denoising sudah dilakukan ditahap preprocessing. Untuk pembuatan model adalah layer autoencoder yang berisi *encoder* dan *decoder*. Pembuatan model *encoder* yang merupakan implementasi dari *Convolutional Neural Network* (CNN). Model *encoder* adalah kebalikan dari model *encoder* untuk merepresentasikan data input menjadi data output yang mirip dengan data inputan. Proses *stacking autoencoder* adalah dengan menambah layer *encoder* dan *decoder*.

f. Stratify Shuffle Split Cross-Validation

Proses ini dilakukan untuk menentukan apakah model yang telah dibuat sudah stabil. Proses cross-validation ini dilakukan dengan menggunakan data yang sudah diolah menggunakan proses CWT yang berjumlah 2369 data dan membaginya menjadi 10 bagian dengan data sama tetapi letak data test dan train yang berbeda, kemudian dilatih sebanyak 15 epoch. Berikut adalah hasil dari cross validation yang sudah dibuat:

Pembagian Data Stratify Shuffle Split	1			2			3			4			5		
Akurasi (%)	52.78	52.27	52.97	54.94	52.84	59.4	54.52	55.11	56.93	57.86	61.93	63.86	59.65	56.82	58.91
Pembagian Data Stratify Shuffle Split	6			7			8			9			10		
Akurasi (%)	59.91	57.39	58.91	52.82	52.27	52.97	53.75	53.41	52.97	58.60	57.38	57.42	58.15	61.36	61.38

Data Train	Data Validasi	Data Test
------------	---------------	-----------

Dapat disimpulkan dari data diatas bahwa model yang sudah dibuat sudah stabil dalam melakukan klasifikasi suara paru dengan jumlah rerataan test diatas 56%.

g. Pelatihan Model

Pelatihan model dilakukan ketika suatu model sudah memiliki kinerja yang baik dan stabil. Model dapat dikatakan stabil bila tidak terjadi *overfitting*. Pelatihan model dilakukan dengan menggunakan 40 *epoch* dengan pembagian data 72.22% data latih dan 12.78% data validasi.

h. Evaluasi Model

Proses ini dilakukan untuk mengetahui kinerja dari model apabila diaplikasikan pada data test sebesar 15% data yang belum pernah digunakan dalam proses pelatihan model. Proses ini berguna untuk mengetahui model memiliki kinerja yang baik atau tidak pada suatu himpunan data tertentu.

i. Metrik evaluasi

Model matrik evaluasi disini adalah menggunakan matrik confusion sehingga didapatkan persebaran dimana saja kelas data test yang benar dan gagal saat model melakukan proses klasifikasi suara paru.

4. Evaluasi dan Analisis

Hasil Pengujian

Model SDAE yang dibuat adalah dengan menggunakan arsitek high, medium, dan low. Ketiga arsitektur tersebut memiliki kedalaman yang sama, namun memiliki jumlah neuron per hidden layer yang berbeda. Arsitek high yaitu dengan model SDAE didalamnya terdapat layer encoder dengan 3 hidden layer yang jumlahnya 512 neuron, 256 neuron, dan 128 neuron dan akan dibalikkan lagi di layer decoder dengan jumlah yang sama (3 hidden layer) dengan urutan jumlah neuron adalah kebalikan dari layer encoder (128 neuron, 256 neuron, 512 neuron). Arsitek medium adalah jumlah neuron awal di encoder sebanyak 256 neuron, 128 neuron, 64 neuron dan akan dibalikkan lagi di layer decoder dengan jumlah yang sama dengan urutan jumlah neuron adalah kebalikan dari layer encoder. Arsitek low adalah jumlah neuron awal di encoder sebanyak 128 neuron, 64 neuron, 32 neuron dan akan dibalikkan lagi di layer decoder dengan jumlah yang sama dengan urutan jumlah neuron adalah kebalikan dari layer encoder.

Model SDAE	aktivasi sigmoid arsitek low			aktivasi sigmoid arsitek medium			aktivasi sigmoid arsitek high		
Akurasi(%)	52.8	52.78	52.8	52.84	53.12	52.8	52.83	51.74	52.8
Model SDAE	aktivasi tanh arsitek low			aktivasi tanh arsitek medium			aktivasi tanh arsitek high		
Akurasi (%)	58.17	57.99	59.83	62.92	58.33	59.55	66.3	60.07	63.48
Model SDAE	aktivasi ReLU arsitek low			aktivasi ReLU arsitek medium			aktivasi ReLU arsitek high		
Akurasi (%)	59.65	60.76	59.55	60.13	58.33	61.23	71.57	63.54	67.97

Data Train	Data Validasi	Data Test
------------	---------------	-----------

Berdasarkan hasil pengujian terhadap ketiga arsitektur model mesin pembelajaran, dapat disimpulkan bahwa model dengan arsitektur tinggi memiliki kinerja yang baik untuk mengklasifikasikan data suara paru. Dari hasil perbandingan dengan menggunakan fungsi aktivasi dapat disimpulkan bahwa fungsi aktivasi *ReLU* memiliki akurasi yang baik untuk mengklasifikasikan suara paru. Jadi model SDAE dengan arsitek high dan menggunakan fungsi aktivasi *ReLU* memiliki akurasi yang optimal untuk mengklasifikasikan suara paru sebesar 67,97%.

Analisis Hasil Pengujian

Dari hasil beberapa arsitektur yang digunakan bahwa dapat disimpulkan bahwa semakin dalam model maka akan semakin dalam proses pembelajaran yang dilakukan oleh mesin. Tetapi hal itu juga bisa menyebabkan model tidak stabil dan memperbesar kemungkinan terjadinya *overfitting*.

Berdasarkan hasil dari pengujian terhadap pencarian fungsi aktivasi juga dapat disimpulkan bahwa fungsi aktivasi yang memiliki aktivasi neuron yang memiliki pembatas nol dan jika lebih maka akan terus naik akan membuat proses dari pembelajaran mesin menjadi lebih baik. Namun hal ini juga berkemungkinan mematikan neuron selamanya selama proses training.

Akurasi yang didapatkan dari model ini sudah baik dengan mendapatkan 67.97% dari akurasi data test dengan penentuan hyper parameter yang tepat yaitu menggunakan fungsi aktivasi *ReLU* dan menggunakan model arsitek dengan jumlah neuron di hidden layer sebanyak 512 neuron di hidden layer pertama (layer encoder), 256 neuron di hidden layer kedua (layer encoder), 128 neuron di hidden layer ketiga (layer encoder), 128 di hidden layer keempat (layer decoder), 256 neuron di hidden layer kelima (layer decoder), dan 512 neuron di hidden layer terakhir (layer decoder).

Selain itu juga data yang dipakai di model ini sangat tidak seimbang dengan dibagi menjadi 4 kelas, terdapat 1 kelas dengan data lebih dari 50% dan terdapat 2 kelas yang hanya memiliki 7% dan 12% data saja. Hal ini membuat pembelajaran mesin memiliki kinerja yang kurang baik.

5. Kesimpulan

Berdasarkan pengujian yang telah dilakukan maka dapat disimpulkan:

1. Klasifikasi Suara paru dapat dilakukan dengan menggunakan algoritma *Continuous Wavelet Transform* untuk merubah data menjadi scalogram dan *Stacked Denoising Autoencoder* sebagai klasifikasinya.
2. Dalam percobaan klasifikasi suara paru dengan mengklasifikasikannya kedalam 4 kelas yang ada yaitu kelas normal, kelas *crackel*, kelas *wheeze*, serta kelas crackel dan wheeze didapatkan hasil akurasi yang optimal sebesar 67,97% dengan menggunakan model arsitektur yang memiliki banyak neuron dalam pembuatan model dan menggunakan fungsi aktivasi *ReLU*.

Daftar Pustaka

- [1] Achmad Rizal, Risanuri Hidayat, Hanung Adi Nugroho, "Lung Sounds Classification using Spectrogram's First Order Statistics Features," 2016.
- [2] Adnan Hassal Falah, Jondri, M.Si, "Klasifikasi Suara Paru Normal Dan Abnormal Menggunakan Deep Neural Network dan Support Vector Machine," 2019.
- [3] Chandraditya Aridela, Achmad Rizal, ST., MT., Yuli Sun Hariyani, ST.MT., "Perbandingan Suara Paru Normal Dan Abnormal Menggunakan Probabilistic Neural Network Dan Support Vector Machine," 2017.
- [4] Hanung Tyas Saksono, Achmad Rizal., Koredianto Usman, "Pendeteksian Kanker Paru-Paru Dengan Menggunakan Transformasi Wavelet Dan Metode Linear Discriminant Analysis," 2010.
- [5] F. Ningsih, "Ekstraksi Ciri dan Identifikasi Sinyal Suara Jantung S1 dan S2 Phonocardiogram (PCG) menggunakan Metode Continuous Wavelet Transform," 2018.
- [6] Q. V. Le, "Part 2: Autoencoders, Convolutional Neural Networks and Recurrent Neural Networks," in *A Tutorial on Deep Learning*, 2015.
- [7] Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., and Manzagol, P.-A, "Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning*," 2010.
- [8] Tedy Suwega, Jondri, M.Si., Untari Novia Wisesty, S.T, M.T., "Denoising Sinyal EKG Menggunakan Deep Neural Network Dengan Staked Denoising Autoencoders," 2017.
- [9] Ilham Muhammad, Jondri, M.Si., Untari Novia Wisesty, S.T, M.T., "Klasifikasi Sinyal ECG Menggunakan Deep Learning Dengan Stacked Denoising Autoencoders," 2017.
- [10] Suyanto, *Machine Learning Tingkat Dasar dan Lanjut*, 2018.