

Klasifikasi Suara Paru Normal dan Abnormal dengan Menggunakan Discrete Wavelet Transform dan Support Vector Machine

Anisa Septiani, Jondri², Achmad Rizal³

^{1,2}Fakultas Informatika, ³Fakultas Elektro Universitas Telkom, Bandung
¹anisaseptiani@students.telkomuniversity.ac.id, ² jondri@telkomuniversity.ac.id, ³
achmadrizal@telkomuniversity.ac.id

Abstrak

Suara paru adalah salah satu informasi penting dalam diagnosa penyakit pada pernafasan paru-paru. Teknik yang digunakan dokter untuk melakukan diagnosa pada suara paru adalah teknik auskultasi, mayoritas hasil dari diagnosa dengan menggunakan teknik auskultasi menyebabkan hasil yang subjektif. pada penelitian ini metode yang digunakan adalah *Discrete Wavelet Transform (DWT)* dengan *single wavelet* dengan tipe DWT bior 3.3 dan *Time Domain Feature (TDF)* dengan enam perhitungan yaitu *mean, kurtosis, standart deviation, skewness, variance, mean absolute deviation*. Untuk melakukan klasifikasi tersebut menggunakan metode *Support Vector Machine (SVM)* dengan *Grid Search Hyperparameter Tuning* untuk mendapatkan parameter yang baik pada SVM, hasil akurasi pada klasifikasi ini sebesar 60% dengan $C = 10$, $\text{Gamma} = 1$, dan $\text{Kernel} = \text{Rbf}$.

Kata Kunci: *Discrete Wavelet Transform, Time Domain Feature, Support Vector Machine*

Abstract

Lung sounds are one of the important information in diagnosing diseases of the respiratory tract of the lungs. The technique that doctors use to diagnose lung sounds is auscultation technique, the majority of the results of the diagnosis using auscultation techniques lead to subjective results. In this study, the method used is *Discrete Wavelet Transform (DWT)* with a *single wavelet* with DWT type 3.3 and *Time Domain Feature (TDF)* with six calculations, namely *mean, kurtosis, standard deviation, skewness, variance, mean absolute deviation*. To perform this classification using the *Support Vector Machine (SVM)* method with *Grid Search Hyperparameter Tuning* to get good parameters on the SVM, the accuracy of this classification is 60% with $C = 10$, $\text{Gamma} = 1$, and $\text{Kernel} = \text{Rbf}$.

Keyword: *Discrete Wavelet Transform, Time Domain Feature, Support Vector Machine LAST, Apache spark, Hadoop*

1. Pendahuluan

1.1 Latar Belakang

Pada perkembangan teknologi biomedis, banyak penelitian-penelitian yang telah dibuat untuk bisa membantu pekerjaan dokter, salah satunya untuk mendiagnosis penyakit. Penyakit paru-paru merupakan salah satu penyakit yang berbahaya selain jantung dan stroke [1], suara paru merupakan salah satu informasi yang digunakan dokter untuk menentukan bagaimana tingkat kesehatan pernafasan pada paru-paru seseorang. Secara klinis, dalam menentukan dan mendiagnosis penyakit tersebut, dokter akan menggunakan sebuah Teknik auskultasi. Teknik ini berfungsi untuk mendiagnosa penyakit paru-paru dengan cara mendengarkan suara paru dengan menggunakan stetoskop. Dalam Teknik auskultasi, memiliki banyak keterbatasan pada dokter dalam menentukan diagnosis penyakit pada paru-paru, dikarenakan beberapa faktor yang mempengaruhi diagnosis, seperti kepekaan telinga dan pola suara yang relatif sama, oleh karena itu, hasil diagnosis penyakit pada paru-paru, dibutuhkan ketelitian yang lebih. Dengan dilakukannya penelitian ini diharapkan dapat mengetahui bagaimana pengaruh dari hasil klasifikasi suara paru untuk meningkatkan ketelitian yang lebih dalam diagnosis penyakit tersebut [2].

Dalam penelitian sebelumnya, Achmad Rizal, Risanuri Hidayat, Hanung Adi Nugroho melakukan penelitian tentang suara paru yang berjudul "Determining lung sound characterization using Hjorth descriptor" di tahun 2015, Penelitian ini membuat sistem untuk klasifikasi suara paru dengan menggunakan metode Hjorth Descriptors dan K-means clustering dengan akurasi sebesar 77% [2]. Pada tahun 2016 Qiyu Chen, Weibin Zhang, Xiang Tian, Xiaoxue Zhang, Shaoqiong Chen, dan Wenkang Lei melakukan penelitian dengan judul "Automatic Heart and Lung Sounds Classification using Convolutional Neural Networks". Penelitian ini membuat sebuah klasifikasi terhadap suara jantung dan suara paru-paru dengan menggunakan metode klasifikasi yaitu Convolutional Neural Network (CNN). Akurasi klasifikasi pada penelitian tersebut sebesar 97.80% [3].

Selain itu, penggunaan Discrete Wavelet Transform (DWT) pada kompresi signal menjadi metode yang populer dan sering digunakan pada penelitian suara paru [4] [5] [6]. Pada metode ekstraksi ciri Time Domain Feature (TDF) telah digunakan pada beberapa penelitian untuk mendapatkan ciri dengan data yang berbentuk Time series seperti penelitian yang dibuat oleh Shazwani Ahmad Shufni dan Mohd Yusoff Mashor dengan judul "ECG Signals Classification Bases on Discrete Wavelet Transform, Time Domain and Frequency Domain Features" Sinyal yang digunakan pada penelitian ini berupa sinyal ECG dengan menggunakan Fourier Transform dan Discrete Wavelet Transform (DWT) untuk transformasi sinyal serta feature yang dibandingkan adalah DWT dengan perhitungan Standart Deviaton, Time Domain Features (TDF) dan Frequency Domain Features dengan metode klasifikasinya adalah Artificial Neural Network (ANN). Pada proses Discrete Wavelet Trasnfrom (DWT) memberikan akurasi dengan rata-rata 90% [4].

Dalam permasalahan ini, penulis ingin membuat sebuah sistem klasifikasi atau membuat deteksi penyakit paru-paru normal dan abnormal dengan menggunakan Discrete Wavelet Transform (DWT) untuk kompresi sinyal serta menggunakan Time Domain Feature (TDF) untuk mendapatkan ciri dari masing-masing sinyal. Data yang sudah diolah akan dilakukan proses klasifikasi dengan menggunakan Support Vector Machine (SVM).

1.2 Topik dan Batasan

Topik yang dibahas pada tugas akhir ini adalah bagaimana memproses dan membuat sebuah klasifikasi suara paru normal dan abnormal dengan menggunakan metode ekstraksi ciri DWT, TDF dan SVM sebagai metode klasifikasinya, dan menganalisis tipe mother wavelet pada metode DWT.

Batasan-batasan dari penelitian tugas akhir ini adalah data yang diambil adalah data sekunder yang tidak langsung diambil dari pasien. Penggunaan jumlah label dataset yang diambil pada penelitian ini hanya 3 label yaitu, crackle, wheeze, dan normal.

1.3 Perumusan Masalah

1. Bagaimana sistem klasifikasi suara paru normal dan abnormal?
2. Bagaimana hasil dari ekstraksi ciri menggunakan DWT dan TDF dan metode klasifikasi SVM?

1.4 Tujuan

Tujuan pada penelitian tugas akhir ini adalah untuk mengetahui bagaimana sistem klasifikasi suara paru normal dan abnormal menggunakan metode klasifikasi SVM dan untuk mengetahui hasil dari klasifikasi serta ekstraksi ciri menggunakan DWT, TDF dan SVM.

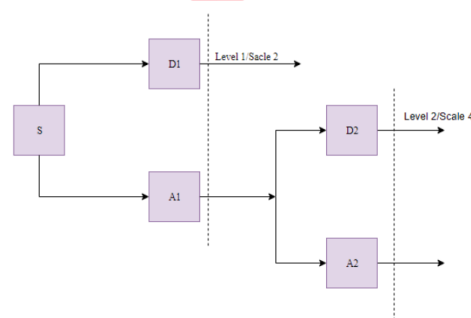
2. Studi Terkait

2.1 Suara Paru

Suara paru merupakan sebuah informasi penting untuk mengetahui tingkat kesehatan pada organ paru-paru. Suara paru terbagi menjadi dua jenis, yaitu pernapasan dengan suara normal dan abnormal. Terdapat beberapa jenis suara paru abnormal yaitu, wheeze dan crackle. Suara wheeze didefinisikan sebagai suara kontinu bernada tinggi seperti siulan yang disebabkan oleh penyempitan pernafasan, wheeze mengandung frekuensi dominan diatas 400 Hz, penyakit yang berhubungan dengan suara paru wheeze adalah asma, pneumonia, dan bronchitis [7]. Suara crackle adalah suara adventif yang terputus-putus, disebabkan oleh pembukaan tiba-tiba pada saluran udara kecil yang telah runtuh mengandung frekuensi lebih rendah dari wheeze [8], Suara crackle terdengar pada pengidap fibrosis paru, dan gagal jantung kongestif [7].

2.2 Discrete Wavelet Transform (DWT)

Discrete Wavelet Transform (DWT) merupakan metode yang berfungsi untuk membagi sinyal yang cocok untuk denoising dan kompresi sinyal [6]. Langkah umum dalam Teknik DWT yaitu, sinyal dibagi menjadi *sub-band*, frekuensi tinggi dan *sub-band* frekuensi rendah atau yang disebut *sub-band low pass* dan *sub-band high pass* [4].



Gambar 1 Ilustrasi DWT

Pada Gambar 1, Sinyal dibagi menjadi *sub-band low pass* dan *sub-band high pass* dengan A disimbolkan sebagai *Approximation filter low pass* dan D sebagai *Detail filter high pass*. Pembagian sinyal dalam satu proses filterisasi disebut sebagai dekomposisi [9]. Proses tersebut diulang beberapa kali sesuai dengan *level* DWT. Dengan adanya DWT dapat membantu menganalisis sinyal pada subband yang semakin sempit pada resolusi yang berbeda.

2.3 Time Domain Features (TDF)

Time Domain Features (TDF) merupakan metode ekstraksi ciri yang dihitung dari nilai-nilai amplitudo sinyal sesuai dengan panjang waktu, metode ini memiliki beberapa contoh perhitungan untuk mendapatkan ciri pada sinyal [11] [12].

1. Mean

$$\text{mean}(\mu) = \frac{1}{N} \sum_{n=1}^N X_n$$

2. Variance

$$\text{var} = \frac{1}{N-1} \sum_{n=1}^N (X_n - \mu)^2$$

3. Standard Deviation


$$std(\sigma) = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (X_{n-1} - \mu)^2}$$

4. Skewness

$$skew = \frac{\frac{1}{N} \sum_{n=1}^N (X_n - \mu)^3}{\sigma^3}$$

5. Mean Absolute Deviation

$$MAD = \frac{1}{N} \sum_{n=1}^N |X_n - O RT|$$




6. Kurtosis

$$kurt = \frac{\frac{1}{N} \sum_{n=1}^N (X_n - \mu)^4}{\sigma^4}$$

2.4 Grid Search Hyperparameter Tuning

Hyperparameter adalah parameter tertentu yang dapat mengontrol sebuah algoritma dengan melakukan penyetelan untuk mendapatkan prediksi yang lebih baik. *Grid Search* secara sistematis akan mencari semua kemungkinan dengan parameter yang telah ditentukan sebelumnya [13].




Gambar 2 konsep Grid Search

Pada Gambar 3 *Hyperparameter 1* = [a,b,c] dan *hyperparameter 2* = [o,p,q] merupakan parameter yang telah dipilih sebelumnya, hal ini akan dilakukan percobaan semua kemungkinan pada parameter yang telah ditentukan, hasil yang paling baik akan diambil sebagai parameter pada algoritma tertentu [13].

2.5 Support Vector Machine (SVM)

Support Vector Machine (SVM) diperkenalkan oleh Vapnik pada tahun 1992, pada awalnya SVM digunakan untuk klasifikasi data ke dalam dua kelas, perkembangan SVM diperluas dan dapat mengklasifikasi lebih dari dua kelas, dalam hal ini terbentuklah dua jenis klasifikasi pada SVM yaitu *Binary Class SVM* dan *Multi Class SVM*. Konsep pada SVM adalah menemukan *hyperplane* yang dapat memisahkan himpunan data. SVM berusaha menemukan *hyperplane* paling optimum [14].



Gambar 3 Ilustrasi SVM

Untuk data yang terpisah secara *non* linear, menggunakan konsep kernel. Terdapat beberapa jenis fungsi kernel pada SVM yaitu [14]:

1. Kernel Polynomial

$$K(x, x_k) = x_k^T x + 1$$


2. Kernel Gaussian (*Radial Basis Function* (RBF))

$$K(x, x_k) = \exp \exp \{-||x - x_i||_2^2 \sigma^2\}$$

3. Kernel Sigmoid

$$K(x, x_k) = \tanh \tanh [k x_k^T x + \theta]$$

3. Sistem yang Dibangun



Gambar 4 Skema Sistem Perancangan

Gambar 4 merupakan diagram *blok* proses perancangan *sistem*. Dataset yang digunakan merupakan dataset dari *International conference in Biomedical and Health Informatics ICHBI 2017*, label untuk proses klasifikasi ini terdapat tiga label yaitu *normal*, *crackle*, dan *wheeze* dengan dua siklus pernafasan yaitu inspirasi dan ekspirasi. Dalam proses *preprocessing* dilakukan perubahan dataset suara menjadi data sinyal. Pada proses selanjutnya masih dalam proses *preprocessing* yaitu dilakukannya normalisasi data berupa *Resample* frekuensi. Setelah dilakukannya *resample*, tahap selanjutnya adalah *minmax scaler* dengan *range* -1 hingga 1. Dengan data yang diproses sebelumnya, data akan diinput dan akan dilakukannya proses DWT. Data tersebut akan didekomposisi menjadi 1 level *subband* DWT untuk mengkompresi sinyal dan menghilangkan *denoising*, masing-masing sinyal yang telah dilakukan proses DWT akan diambil beberapa ciri dengan menggunakan metode *Time Domain Features* (TDF) dengan TDF yang digunakan yaitu *mean*, *skewness*, *standard deviation*, *variance*, *kurtosis*, *mean absolute deviation*. Hasil tersebut akan menjadi inputan pada proses *classification* dengan menggunakan SVM, setelah mendapatkan hasil dari klasifikasi, dilakukannya validasi data berupa *K-fold cross validation*

3.1 Data Suara Paru


Data suara paru yang digunakan diperoleh dari *International conference in Biomedical and Health Informatics (ICHBI) 2017* yang berjumlah 274 informasi data, file berformat txt dan wav. Data txt tersebut berisi informasi siklus pernapasan beserta waktu pernafasannya dengan label dari masing-masing data suara paru, sedangkan untuk data berupa *.wav berisi suara paru. Pada dataset ini akan dibagi tiga pengujian, yang pengujian pada data set ini yang pertama yaitu menggabungkan kedua siklus yaitu inspirasi dan ekspirasi, yang kedua hanya data siklus inspirasi dan yang ketiga dataset siklus ekspirasi, pada tugas akhir ini label data yang digunakan hanya tiga label, berupa normal, *crackle*, dan *wheeze* dan akurasi siklus pernafasan yang paling bagus akan dijadikan model untuk melakukannya klasifikasi data.

3.2 Preprocessing Data Suara Paru

Pada *preprocessing* ini akan dilakukan beberapa tahapan normalisasi dataset yang akan digunakan sebagai inputan pada *feature extraction* dan *classification*. Beberapa tahap *preprocessing* yang dilakukan:

1. Merubah data suara menjadi sinyal dan memisahkan antara siklus pernapasan inspirasi dan ekspirasi.
2. *Resample* Frekuensi Data


Pada proses *resample* dilakukannya proses *resample* frekuensi data dari 44,1 Khz menjadi 8 Khz, Proses yang diambil pada *resample* frekuensi ini adalah *resample* yang diperlukan untuk mengurangi jumlah *sample* sehingga waktu komputasi dan kompleksitasnya dapat dikurangi dan hal ini dilakukan untuk memperkecil dan menyetarakan frekuensi yang dapat memudahkan dalam proses *feature extraction* dan *classification* [5] [12].



Gambar 5 Sebelum dan sesudah *Resample* Data

3. *Minmax Scaler*

Minmax Scaler ini termasuk pada normalisasi data, yang berfungsi untuk *scaling* data atau menyesuaikan data dalam *range* tertentu. *Range* nilai minimum hingga *range* nilai maksimum, dengan rentang -1 hingga 1 [15].



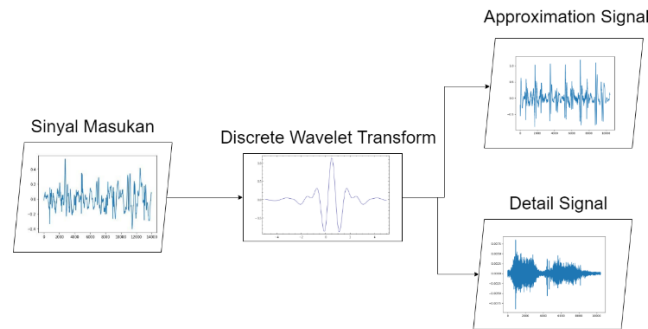
Gambar 6 Sebelum dan Sesudah dilakukannya *Minmax Scaler* range -1 hingga 1

3.3 Feature Extraction

Setelah dilakukannya *preprocessing*, tahap selanjutnya adalah ekstraksi ciri menggunakan *Discrete Wavelet Transform (DWT)* dan *Time Domain Feature (TDF)*.

1. *Discrete Wavelet transform (DWT)*

Discrete Wavelet transform (DWT) ini berfungsi untuk membagi frekuensi sinyal menjadi *sub-band*. Jika menggunakan *single* DWT dapat digambarkan seperti berikut.



Gambar 7 skema pembagian frekuensi

Pada Gambar 7 merupakan sebuah skema dari *Single Wavelet* satu level, sinyal masukan berupa *time series* dilakukannya proses transformasi menggunakan DWT dengan beberapa tipe *mother wavelet* sebagai percobaannya, menghasilkan dua kondisi sinyal yaitu *approximation* yang berisikan sinyal frekuensi yang lebih rendah dari sinyal masukan sebelumnya sedangkan *detail* sinyal merupakan sinyal yang cenderung memiliki frekuensi lebih tinggi atau kerapatan sinyal yang lebih rapat dibanding *approximation* [5].

```
['bior1.1', 'bior1.3', 'bior1.5', 'bior2.2', 'bior2.4', 'bior2.6', 'bior2.8', 'bior3.1', 'bior3.3', 'bior3.5', 'bior3.7', 'bior3.9', 'bior4.4', 'bior5.5', 'bior6.8', 'coif1', 'coif2', 'coif3', 'coif4', 'coif5', 'coif6', 'coif7', 'coif8', 'coif9', 'coif10', 'coif11', 'coif12', 'coif13', 'coif14', 'coif15', 'coif16', 'coif17', 'db1', 'db2', 'db3', 'db4', 'db5', 'db6', 'db7', 'db8', 'db9', 'db10', 'db11', 'db12', 'db13', 'db14', 'db15', 'db16', 'db17', 'db18', 'db19', 'db20', 'db21', 'db22', 'db23', 'db24', 'db25', 'db26', 'db27', 'db28', 'db29', 'db30', 'db31', 'db32', 'db33', 'db34', 'db35', 'db36', 'db37', 'db38', 'dmey', 'haar', 'rbio1.1', 'rbio1.3', 'rbio1.5', 'rbio2.2', 'rbio2.4', 'rbio2.6', 'rbio2.8', 'rbio3.1', 'rbio3.3', 'rbio3.5', 'rbio3.7', 'rbio3.9', 'rbio4.4', 'rbio5.5', 'rbio6.8', 'sym2', 'sym3', 'sym4', 'sym5', 'sym6', 'sym7', 'sym8', 'sym9', 'sym10', 'sym11', 'sym12', 'sym13', 'sym14', 'sym15', 'sym16', 'sym17', 'sym18', 'sym19', 'sym20']
```

Gambar 8 Tipe-tipe Mother Wavelet

2. Time Domain Features (TDF)

Time Domain Feature (TDF) merupakan metode ekstraksi ciri yang digunakan pada tahap selanjutnya, pada metode ini dilakukan perhitungan untuk mendapatkan ciri dari setiap sinyal, TDF yang digunakan adalah *mean, skewness, standard deviation, variance, kurtosis, mean absolute deviation*.

Tabel 1 Beberapa hasil perhitungan dari ekstraksi ciri

Mean	Standar Deviation	Mean Absolute Deviation	Variance	Skewness	Kurtosis	Kelas
-0.0001500797239236727	0.2543195844396802	0.17214980996817522	0.06468463680338855	0.44658880508376286	2.93666786138741	0
0.001388834277546	0.237699623274445	0.160400262858480	0.056506397311148	0.385026309441508	2.605143154164627	0

4793	6	47	02	45		
------	---	----	----	----	--	--

3.4 Classification

Setelah dilakukan ekstraksi ciri, tahap selanjutnya adalah klasifikasi pada sinyal paru-paru, karena label yang digunakan sebanyak tiga label, maka jenis SVM yang digunakan adalah *multi class*. Pada penelitian ini, mencoba menggunakan tiga kernel yaitu rbf, polynomial, dan sigmoid, dengan empat parameter C yaitu (0.001, 0.1, 1, 10) dan gamma yang digunakan (1,0.1,0.01,0.001). Dengan menggunakan *Grid Search Hyperparameter Tuning*, akan mencari semua kemungkinan dengan parameter yang telah ditentukan, untuk mendapatkan parameter yang baik untuk dilakukannya klasifikasi.

3.5 Skenario Pengujian

- Skenario 1
Pada skenario pengujian ini, dilakukannya pengujian beberapa tipe-tipe *mother wavelet* DWT, untuk mendapatkan hasil ekstraksi ciri.
- Skenario 2
Pada skenario 2 dilakukannya pengujian untuk mendapatkan hyperparameter yang baik dalam melakukan klasifikasi suara paru menggunakan *grid search*.
Pada pengujian selanjutnya data yang telah diproses dan memiliki ciri dibagi menjadi dua bagian yaitu yaitu data *test* dan data *train* menggunakan *K-Fold Cross Validation* untuk menguji akurasi terhadap model tersebut. Pada penelitian ini *K-Fold* yang digunakan terhadap data yaitu dengan K 10.

4. Hasil Pengujian dan Evaluasi

Berikut ini adalah hasil pengujian skenario yang dilakukan terhadap data suara paru ICHBI 2017.

4.1 Hasil Pengujian Skenario 1

Pada pengujian ini dilakukannya percobaan tipe *mother wavelet*, beberapa hasil dari percobaan tersebut.

Tabel 2 hasil percobaan

Nama Wavelet	Akurasi
Bior3.3	0.6086236436322101
Coif1	0.5959451741861793
Daubechies34	0.5939653531315437
Rbior5.5	0.6017704169046258
Haar	0.5949647820293166

Dari tabel diatas Bior 3.3 merupakan tipe *mother wavelet* yang memiliki akurasi terbaik diantara yang lainnya.

4.2 Hasil Pengujian Skenario 2

Hasil daripada *Hyperparameter Tuning* dengan *Grid Search* menghasilkan data seperti yang tertampil pada Tabel 3. Data yang memiliki akurasi tertinggi akan dipilih sebagai penentuan parameter untuk dipergunakan pada Metode SVM.

Tabel 3 Hasil Grid Search Hyperparameter Tuning untuk SVM

Grid Search	Akurasi
{'C': 0.1, 'gamma': 1, 'kernel': 'rbf'}	0.562044
{'C': 0.1, 'gamma': 1, 'kernel': 'sigmoid'}	0.459854
{'C': 0.1, 'gamma': 1, 'kernel': 'poly'}	0.562044
{'C': 0.1, 'gamma': 0.1, 'kernel': 'rbf'}	0.562044
{'C': 0.1, 'gamma': 0.1, 'kernel': 'sigmoid'}	0.562044
{'C': 0.1, 'gamma': 0.1, 'kernel': 'poly'}	0.562044
{'C': 0.1, 'gamma': 0.01, 'kernel': 'rbf'}	0.562044
{'C': 0.1, 'gamma': 0.01, 'kernel': 'sigmoid'}	0.554745
{'C': 0.1, 'gamma': 0.01, 'kernel': 'poly'}	0.562044
{'C': 0.1, 'gamma': 0.001, 'kernel': 'rbf'}	0.562044
{'C': 0.1, 'gamma': 0.001, 'kernel': 'sigmoid'}	0.562044
{'C': 0.1, 'gamma': 0.001, 'kernel': 'poly'}	0.562044
{'C': 1, 'gamma': 1, 'kernel': 'rbf'}	0.562044
{'C': 1, 'gamma': 1, 'kernel': 'sigmoid'}	0.474453
{'C': 1, 'gamma': 1, 'kernel': 'poly'}	0.562044
{'C': 1, 'gamma': 0.1, 'kernel': 'rbf'}	0.576642
{'C': 1, 'gamma': 0.1, 'kernel': 'sigmoid'}	0.459854
{'C': 1, 'gamma': 0.1, 'kernel': 'poly'}	0.562044
{'C': 1, 'gamma': 0.01, 'kernel': 'rbf'}	0.554745
{'C': 1, 'gamma': 0.01, 'kernel': 'sigmoid'}	0.547445
{'C': 1, 'gamma': 0.01, 'kernel': 'poly'}	0.562044
{'C': 1, 'gamma': 0.001, 'kernel': 'rbf'}	0.562044
{'C': 1, 'gamma': 0.001, 'kernel': 'sigmoid'}	0.562044
{'C': 1, 'gamma': 0.001, 'kernel': 'poly'}	0.562044
{'C': 10, 'gamma': 1, 'kernel': 'rbf'}	0.591241
{'C': 10, 'gamma': 1, 'kernel': 'sigmoid'}	0.481752
{'C': 10, 'gamma': 1, 'kernel': 'poly'}	0.576642
{'C': 10, 'gamma': 0.1, 'kernel': 'rbf'}	0.569343
{'C': 10, 'gamma': 0.1, 'kernel': 'sigmoid'}	0.452555
{'C': 10, 'gamma': 0.1, 'kernel': 'poly'}	0.554745

{'C': 10, 'gamma': 0.01, 'kernel': 'rbf'}	0.547445
{'C': 10, 'gamma': 0.01, 'kernel': 'sigmoid'}	0.467153
{'C': 10, 'gamma': 0.01, 'kernel': 'poly'}	0.562044
{'C': 10, 'gamma': 0.001, 'kernel': 'rbf'}	0.562044
{'C': 10, 'gamma': 0.001, 'kernel': 'sigmoid'}	0.554745
{'C': 10, 'gamma': 0.001, 'kernel': 'poly'}	0.562044
{'C': 100, 'gamma': 1, 'kernel': 'rbf'}	0.576642
{'C': 100, 'gamma': 1, 'kernel': 'sigmoid'}	0.481752
{'C': 100, 'gamma': 1, 'kernel': 'poly'}	0.583942
{'C': 100, 'gamma': 0.1, 'kernel': 'rbf'}	0.576642
{'C': 100, 'gamma': 0.1, 'kernel': 'sigmoid'}	0.467153
{'C': 100, 'gamma': 0.1, 'kernel': 'poly'}	0.562044
{'C': 100, 'gamma': 0.01, 'kernel': 'rbf'}	0.576642
{'C': 100, 'gamma': 0.01, 'kernel': 'sigmoid'}	0.328467
{'C': 100, 'gamma': 0.01, 'kernel': 'poly'}	0.562044
{'C': 100, 'gamma': 0.001, 'kernel': 'rbf'}	0.547445
{'C': 100, 'gamma': 0.001, 'kernel': 'sigmoid'}	0.540146
{'C': 100, 'gamma': 0.001, 'kernel': 'sigmoid'}	0.562044

Dari hasil yang didapatkan pada Tabel 3, dengan parameter terbaik adalah $C = 1$ $\Gamma = 1$ Kernel = Rbf, $C = 1$ $\Gamma = 1$ Kernel = Polynomial dan $C = 10$ $\Gamma = 1$ Kernel = Rbf dengan akurasi 0.59, beberapa parameter tersebut akan dipakai untuk klasifikasi Suara paru, hasil terbaik setelah masuk pada K-fold *Validation* yaitu pada parameter $C = 10$ $\Gamma = 1$ Kernel = Rbf. Pada K-fold dilakukannya proses 10 kali pada proses *Validation* dengan rata-rata akurasi seperti pada Tabel 4.

Tabel 4 Hasil dari K-fold Validation $C = 10$ $\Gamma = 1$ Kernel = Rbf

No	Akurasi
1	0.592
2	0.611
3	0.627
4	0.647
5	0.598

6	0.637
7	0.647
8	0.500
9	0.578
10	0.637
Rata-Rata Akurasi	0.607

Dengan memiliki masing-masing akurasi kelas yaitu crackle, wheeze, dan normal seperti pada table 5. Yang dibagi tiga skenario pembagian siklus data pernafasan yaitu, inspirasi, ekspirasi dan keduanya.

Tabel 5 Hasil akurasi tiap kelas

Ekspirasi	
Akurasi Keseluruhan	60%
Akurasi Normal	92%
Akurasi cracle	28%
Akurasi Wheeze	2%
Inspirasi	
Akurasi Keseluruhan	59%
Akurasi Normal	94%
Akurasi cracle	18%
Akurasi Wheeze	0%
Inspirasi dan Ekspirasi	
Akurasi Keseluruhan	56%
Akurasi Normal	93%
Akurasi cracle	24%
Akurasi Wheeze	1%

Dataset yang baik digunakan untuk metode ini adalah ekpirasi dengan akurasinya yang lebih tinggi dibandingkan perbandingan siklus yang lainnya dengan akurasi sebesar 60%

5. Kesimpulan

Pada sistem klasifikasi suara paru normal dan abnormal dengan menggunakan metode klasifikasi SVM memiliki beberapa proses pembuatan sistem dimulai dari preprocessing dengan resample data frekuensi, serta minmax scaler, selanjutnya pada *feature extraction* menggunakan *Discrete Wavelet Transform* dengan *mother wavelet* yang digunakan adalah bior 3.3 dan *Time Domain Feature* yang terdiri dari enam perhitungan yaitu *mean*, *skewness*, *kurtosis*, *mean absolute deviation*, *standart deviation*, *variance*, dan Klasifikasi menggunakan SVM. Dalam proses klasifikasi ini dilakukannya proses *Grid Search Hyperparameter Tuning*. Untuk menentukan *hyperparameter* pada klasifikasi suara paru normal dan abnormal menggunakan metode klasifikasi SVM, dilakukannya sebuah proses *Grid Search Hyperparameter Tuning* untuk mengetahui parameter yang baik untuk dilakukannya sebuah

klasifikasi dengan nilai $C = 10$, $\text{Gamma} = 1$ dan $\text{Kernel} = \text{Rbf}$, Hasil dari ekstraksi dan klasifikasi Suara paru normal dan abnormal memiliki akurasi sebesar 60%. Saran untuk penelitian selanjutnya mungkin bisa mencoba beberapa metode lain untuk bisa meningkatkan akurasi.

Referensi

- [1] K. Kochetov, E. Putin, S. S. I. Azizov and A. & Filchenkov, "Wheeze detection using convolutional neural networks," *EPIA Conference on Artificial Intelligence*, pp. 162-173, 2017.
- [2] D. Bardou, K. Zhang and S. M. & Ahmad, "Lung sounds classification using convolutional neural networks," *Artificial intelligence in medicine*, 2018.
- [3] Q. Z. W. T. X. Z. X. C. S. & L. W. Chen, "Automatic heart and lung sounds classification using convolutional neural networks," *Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA)*, 2016.
- [4] A. Rizal, R. Hidayat and H. A. & Nugroho, "Lung Sound Classification Using Hjorth Descriptor Measurement on Wavelet Sub-bands," *Journal of Information Processing Systems*, p. 15, 2019.
- [5] A. Rizal, T. L. Mengko and A. B. & Suksmono, "Lung sound recognition using wavelet packet decomposition and ART2 (adaptive resonance theory 2) neural network," *Proceeding Biomedical Engineering*, pp. 2, 2-6., 2006.
- [6] L. Pasti, B. Walczak, D. L. Massart and P. & Reschiglian, "Optimization of signal denoising in discrete wavelet transform.," *Chemometrics and intelligent laboratory systems*, pp. 48(1), 21-34., 1999.
- [7] R. Naves, B. H. Barbosa and D. D. & Ferreira, "Classification of lung sounds using higher-order statistics: A divide-and-conquer approach.," *Computer methods and programs in biomedicine*, pp. 129, 12-20., 2016.
- [8] S. İçer and Ş. & Genç, "Classification and analysis of non-stationary characteristics of crackle and rhonchus lung adventitious sounds.," *Digital Signal Processing*, pp. 28, 18-27, 2014.
- [9] G. & Ç. L. L. Çetinel, "Robust Chaotic Digital Image Watermarking Scheme based on RDWT and SVD.," *International Journal of Image, Graphics & Signal Processing*, vol. 8(8), 2016.
- [10] D. A. E. G. D. A. M. & A. D. J. Gangopadhyay, "System considerations for the compressive sampling of EEG and ECoG bio-signals.," *IEEE Biomedical Circuits and Systems Conference (BioCAS)*, Vols. (pp. 129-132). IEEE., 2011.
- [11] C. Altın and O. & Er, "Comparison of different time and frequency domain feature extraction methods on elbow gesture's EMG.," *European journal of interdisciplinary studies*, 2016.
- [12] A. Rizal, R. Hidayat and H. A. & Nugroho, "Lung sounds classification using spectrogram's first order statistics features.," *International Annual Engineering Seminar (InAES)*, pp. (pp. 96-100), 2016.
- [13] I. Syarif, A. Prugel-Bennett and G. & Wills, "SVM parameter optimization using grid search and genetic algorithm to improve classification performance.," *Telkomnika*, 2016.
- [14] Suyanto, *Machine Learning Tingkat Dasar dan Lanjutan*, Informatika, Bandung.
- [15] O. Deperlioglu, "Classification of phonocardiograms with convolutional neural networks.," *BRAIN. Broad Research in Artificial Intelligence and Neuroscience*, pp. 9(2), 22-33., 2018.