

KLASIFIKASI SINYAL *PHONOCARDIOGRAM* MENGGUNAKAN METODE *SHORT-TIME FOURIER TRANSFORM* DAN *SUPPORT VECTOR MACHINE*

Faqih Amatya Hendrayan

Fakultas Teknik Telekomunikasi dan Elektro, Program Studi Teknik Telekomunikasi

Institut Teknologi Telkom Purwokerto

Email: 17101055@ittelkom-pwt.ac.id

Dodi Zulherman

Fakultas Teknik Telekomunikasi dan Elektro, Program Studi Teknik Telekomunikasi

Institut Teknologi Telkom Purwokerto

Email: zulherman.dodi@ittelkom-pwt.ac.id

Rahmat Widadi

Fakultas Teknik Telekomunikasi dan Elektro, Program Studi Teknik Biomedis

Institut Teknologi Telkom Purwokerto

Email: rahmat@ittelkom-pwt.ac.id

ABSTRAK

Penggunaan sinyal *phonocardiogram* (PCG) dalam mengekstraksi informasi kondisi kesehatan jantung membutuhkan analisis sinyal yang kompleks. Namun, PCG memiliki keunggulan seperti non invasif dan lebih ekonomis dibandingkan dengan *electrokardiogram* (EKG). Penelitian ini bertujuan untuk mengembangkan sebuah sistem klasifikasi sebagai alat bantu diagnosis kondisi jantung berdasarkan metode *shorttime fourier transform* (STFT) untuk ekstraksi fitur dan *support vector machine* (SVM) untuk klasifikasi. Analisis kinerja sistem rancangan sistem menggunakan dataset sekunder dengan jumlah 2.141 sinyal PCG yang terdiri dari 1958 normal dan 183 abnormal. Pengujian kinerja menggunakan beberapa variasi jenis *window*, yaitu *Hamming*, *Hanning*, dan *Blackman window* pada STFT dan variasi *kernel* serta nilai *C* parameter pada SVM. Berdasarkan hasil pengujian variasi jenis *window* pada STFT, *Hamming window* memiliki kinerja terbaik dengan nilai sensitivitas 62.24 %, spesitifitas 89.47 %, area under ROC curve (AUC) 0.75, serta akurasi sebesar 65.62 %. Kemudian, variasi nilai *C* parameter sebesar 1000 dan *kernel radial basis function* (RBF) pada proses klasifikasi memberikan hasil kinerja terbaik dengan nilai AUC sebesar 0.83. Penelitian ini membuktikan bahwa penggunaan *Hamming window* pada ekstraksi fitur dan nilai *C* parameter 1000, serta variasi *kernel* RBF pada klasifikasi sebagai bentuk model terbaik sistem PCG berbasis STFT dan SVM.

Kata kunci: PCG, ekstraksi fitur, STFT, klasifikasi, SVM

ABSTRACT

Even though utilizing *phonocardiogram* (PCG) signals for diagnosing cardiovascular diseases requires a complex signal-processing method, it provides non-invasive methods and financial advantages compared with *electrocardiogram* (ECG)-based tools. This study aims to develop a classification method for heart condition diagnostic aids that consist of the *short-time Fourier transform* (STFT) method for feature extraction and *support vector machine* (SVM) for classification. The proposed method's performance analysis used a dataset of 2,141 PCG signals consisting of 1958 normal and 183 abnormal heart conditions. We used several windows variations, such as *Hamming*, *Hanning*, and *Blackman*, on STFT, kernel variations, and the *C* parameter values on SVM. The results showed that the *Hamming window* obtains the best value with a sensitivity value of 62.24%, specificity of 89.47%, area under the ROC curve (AUC) of 0.75, and accuracy of 65.62%. Furthermore, the *C* parameter value of 1000 and the *radial basis function* (RBF) kernel in the classification process get the best performance with the AUC value of

0.83. This study proves that the use of the Hamming window in feature extraction and the value of C parameter 1000, as well as the variation of the RBF kernel on the classification as the best form of PCG system based on STFT and SVM

Keywords: PCG, feature extraction, STFT, classification, SVM.

1. PENDAHULUAN

Kardiovaskular merupakan penyebab kematian nomor satu di dunia. Laporan statistik dari Organisasi Kesehatan Dunia (WHO) tahun 2018 mencatat sebanyak 17.9 juta orang meninggal akibat penyakit kardiovaskular, kematian tersebut mewakili 44% dari total keseluruhan kasus kematian akibat penyakit tidak menular [1]. Sebagai tambahan, berdasarkan data Riset Kesehatan Dasar (Riskesdas) tahun 2018, 15 dari 1000 orang, atau sekitar 2.7 juta individu di Indonesia menderita penyakit jantung [2]. Pengembangan perangkat diagnosis sangat dibutuhkan untuk menekan tingginya prevalensi jantung di dunia khususnya di Indonesia, dengan pendekatan metode pengolahan sinyal digital kita bisa membangun sebuah alat bantu diagnosis untuk mendukung penurunan tingkat prevalensi tersebut.

Umumnya diagnosis awal terhadap penyakit jantung dilakukan dengan menggunakan elektrokardiograf yang mendeteksi impuls listrik jantung dalam rentang waktu tertentu. Alat ini menghasilkan sinyal yang disebut dengan sinyal elektrokardiogram (EKG) [3]. Namun, alat ini memiliki beberapa keterbatasan dalam penggunaannya, seperti membutuhkan keahlian khusus agar dapat menghasilkan diagnosis yang tepat dan membutuhkan biaya yang relatif lebih mahal. Oleh karena itu, *phonocardiogram* (PCG) digunakan sebagai alternatif solusi dalam melakukan diagnosis penyakit jantung. PCG adalah sinyal berulang yang menyampaikan informasi penting tentang aktivitas mekanis jantung. Pada individu normal, setiap siklus PCG mengandung dua suara, yang disebut S1 dan S2 [4].

Penggunaan PCG pada klasifikasi jantung normal dan abnormal secara elektronik membutuhkan analisis sinyal yang sangat kompleks karena *noise* yang ikut dalam perekaman dapat mengurangi tingkat keakuratan dalam diagnosis secara klinis [5]. Sebagai contoh suara paru-paru, suara alat pencernaan dan suara percakapan karena penggunaan PCG dilakukan dengan cara menempelkan alat perekam pada kulit yang berada di atas jantung. Penggunaan sinyal PCG membutuhkan analisis sinyal kompleks untuk mengekstraksi dan menganalisis informasi atau fitur-fitur yang terdapat pada sinyal PCG. Oleh karena itu, penggunaan sinyal PCG membutuhkan metode ekstraksi dan klasifikasi untuk menginterpretasikan isi informasi atau pesan yang terkandung di dalam potongan sinyal. Sebagai contoh, *Short Time Fourier Transform* (STFT) merupakan salah satu metode analisis sinyal yang dapat digunakan dalam proses ekstraksi fitur [6]. STFT mencuplik sinyal dalam durasi waktu tertentu, untuk selanjutnya dikonversi kedalam bentuk spektrum di domain waktu. Kemudian sinyal dicuplik selama t detik sehingga posisi sinyal dapat dipetakan dalam dipetakan dalam domain waktu dan frekuensi secara bersamaan [7]. Penggunaan STFT ditujukan untuk menghasilkan fitur sinyal PCG dalam domain waktu dan frekuensi secara bersamaan untuk selanjutnya dijadikan dasar untuk pengklasifikasian penyakit jantung kondisi normal dan abnormal.

Klasifikasi sinyal digital secara otomatis dapat dilakukan untuk membedakan kondisi normal dan abnormal dari sinyal PCG yang telah dilakukan ekstraksi fitur. Metode *Support Vector Machine* (SVM) merupakan salah satu metode yang dapat digunakan dalam pengklasifikasian sinyal PCG [8]. Pada metode klasifikasi, SVM akan menentukan garis yang dapat memotong data menjadi dua kelas secara optimal [7]. Untuk meminimalisir dari kesalahan klasifikasi SVM juga menyediakan *soft margin* dan *kernel trick* yang dapat digunakan sebagai metode optimasi dalam SVM [9]. Uraian tersebut menjadi dasar pemilihan SVM sebagai teknik klasifikasi sinyal PCG untuk mendiagnosis kondisi normal dan abnormal.

Penelitian yang mengimplementasikan metode STFT pada tahap ekstraksi fitur dan metode SVM pada tahap klasifikasi telah dilakukan oleh beberapa peneliti sebelumnya. Penelitian Fransisco Daso, Jusak, dan Ira Puspasari tahun 2015 yang berjudul analisis sinyal suara jantung dengan menggunakan analisis spektrum. Penelitian ini berfokus kepada bagaimana sinyal suara jantung normal dan tidak normal berdasarkan puncak frekuensi untuk ekstraksi fiturnya. Sinyal suara jantung ditransformasikan dan dianalisis dengan algoritma FFT (*Fast Fourier Transform*) untuk

mendapatkan *range* frekuensinya. Hasilnya menunjukkan bahwa pada transformasi sinyal suara jantung normal memiliki *peak* di frekuensi 56 Hz dan frekuensi maksimum 277.5 Hz. Pada jantung yang terdapat kelainan didalamnya (2 katup jantung yang tidak menutup secara bersamaan) terdapat 2 bukit, bukit pertama memiliki *range* 0-70Hz dan bukit kedua memiliki *range* 100-78Hz, sinyal suara jantung ini memiliki frekuensi *peak* 28 Hz dan frekuensi maksimum tercatat sebesar 109.8 Hz. Penelitian ini menunjukkan metode FFT sebagai metode ekstraksi fitur dengan menggunakan informasi dari puncak frekuensi mampu membedakan sinyal jantung normal dan tidak normal [10]. Berdasarkan kajian yang telah dilakukan oleh Fransisco Daso et al. penulis dengan objek yang sama yaitu dengan menggunakan suara jantung bermaksud mengklasifikasikan suara jantung normal dan abnormal dengan metode ekstraksi fitur yang telah ditingkatkan menjadi STFT dan diklasifikasi menggunakan metode SVM.

Penelitian Ira Puspasari pada tahun 2015 tentang analisis non-stationer pada deteksi non invasif sinyal suara jantung koroner. Penelitian ini menyebutkan bahwa ekstraksi ciri merupakan bagian yang sangat penting dalam pengembangan suatu sistem diagnosis suara jantung elektronik. Hal ini menjadikan peneliti melakukan penelitian tentang metode ekstraksi ciri yang efektif untuk mengeksplorasi dinamika data yang terdapat dalam bunyi jantung. Oleh karena itu, lebih lanjut, peneliti mempelajari lebih lanjut *Short Time Fourier Transform* (STFT) sebagai metode ekstraksi ciri. Informasi jantung yang diekstraksikan fiturnya pada penelitian ini adalah *magnitudo*, rata-rata frekuensi dan waktu. Sinyal masukan yang diperoleh diolah menggunakan STFT dengan menggunakan variasi *Hamming Window* dengan lebar 20, sinyal kemudian dihitung menggunakan transformasi *Fourier* hingga diperoleh *magnitudo* sinyal terhadap frekuensi dan *window*. Hasil menunjukkan bahwa rata-rata frekuensi sinyal penyakit jantung koroner (PJK) masing-masing memiliki frekuensi sampel lebih dari 200 Hz. Hal ini dijadikan pedoman sebagai pembeda antara suara jantung normal dan abnormal, dimana suara jantung normal memiliki rentang frekuensi antara 20-200 Hz, dan abnormal memiliki rentang frekuensi hingga 1000 Hz [11]. Berdasarkan kajian yang telah dilakukan oleh Ira Puspasari, penulis dengan objek yang sama serta dengan metode ekstraksi fitur yang serupa bermaksud meningkatkan variasi jenis *window* pada STFT dengan 3 jenis *window* *hamming*, *hanning*, dan *blackman* untuk selanjutnya diklasifikasi menggunakan metode SVM.

Penelitian Engin Avci tahun 2009 tentang sistem diagnosis cerdas baru untuk penyakit katup jantung dengan menggunakan SVM sebagai metode klasifikasi. Avci menggunakan SVM sebagai metode klasifikasi untuk mendiagnosis penyakit jantung (murmur) pada suara jantung dengan ekstraksi ciri menggunakan metode *Discrete Wavelet Transform* (DWT). Metode SVM dipilih karena dapat memilih jenis filter *wavefelet* yang paling tepat, dilakukan juga variasi untuk memilih tipe fungsi kernel, yaitu kernel *Radial Basis Function* (RBF) dan *Exponential Radial Basis Function* (ERBF) dan variasi C parameter dengan nilai 0.1 dan 10.000. Pada penelitian ini, variasi kernel ERBF dan nilai C parameter sebesar 0.1 memperoleh nilai akurasi sebesar 96% untuk jantung normal serta 94.52% untuk akurasi jantung abnormal [12]. Berdasarkan penelitian yang dilakukan oleh Engin Avci di tahun 2009, penulis bermaksud meningkatkan variasi nilai C parameter pada klasifikasi SVM dengan rentang 0.0001, 0.001, 0.01, 1, 10, 100, dan 1000 untuk menghindari peristiwa terjadinya *underfitting* dan *overfitting*.

Penelitian Yutai Wang, Boyuan Sun, Xinghai Yang, dan Qingfang Meng pada tahun 2017 tentang pengenalan suara jantung berdasarkan SVM. Peneliti membagi proses rekognisi kedalam tiga tahapan. Pertama, penggunaan wavelet transform untuk mereduksi *noise* dari suara jantung. Kedua, ekstraksi fitur suara jantung menggunakan MFCC. Ketiga hasil klasifikasi diperoleh melalui SVM dengan menggunakan optimasi tingkat akurasi menggunakan variasi kernel dan nilai dari faktor penalti. Variasi kernel yang digunakan adalah polynomial kernel dan linear kernel, sedangkan untuk jenis faktor penalti yang digunakan adalah C parameter. Hasilnya menunjukkan bahwa kernel linear dengan C=100 menghasilkan tingkat akurasi sebesar 92.82% sedangkan kernel polynomial dengan C=100 hanya mendapatkan nilai akurasi sebesar 86.15% [13]. Berdasarkan penelitian yang dilakukan Wang et al. penulis bermaksud untuk meningkatkan variasi pada jenis kernel dengan menggunakan kernel linear, *polynomial*, dan *Radial Basis Function*


(RBF) untuk selanjutnya dari ketiga variasi kernel tersebut dilakukan optimasi dengan nilai C parameter sebesar 0.0001, 0.001, 0.01, 1, 10, 100, dan 1000.

Md. Riadul Islam, Md. Mahadi Hassan, M. Raihan, Sabuz Kumar Datto, Abdullah Shahriar, dan Arun More pada tahun 2019 merancang penggunaan stetoskop *wireless* elektrik untuk mengklasifikasikan suara jantung abnormal pada anak. Analisa suara jantung yang dilakukan didasarkan pada karakteristik domain waktu dan frekuensi. Suara jantung diekstraksi fiturnya menggunakan metode *Mel-frequency Cepstral Coefficients* (MFCCs), dari proses tersebut didapatkan 5 (lima) fitur yang digunakan sebagai masukan klasifikasi, yaitu *Principal Component Analysis* (PCA), *Singular Value Decomposition* (SVD), Variance, Standar Devisor, *Kernel PCA* (KPCA). Hasil ekstraksi fitur diklasifikasikan menggunakan 4 (empat) model *kernel* yang berbeda, yaitu *Radial Basis Function* (RBF), *polynomial*, *linear*, dan *sigmoid kernel*. Hasilnya menunjukkan bahwa tingkat akurasi terbaik didapatkan oleh kernel RBF sebesar 94.12% [14]. Berdasarkan penelitian Islam et al. penulis bermaksud menggunakan metode serupa dengan membedakan ekstraksi ciri dengan menggunakan metode STFT yang lebih baik digunakan sebagai analisis sinyal non-stationer.

2. METODOLOGI PENELITIAN

2.1 Alur Penelitian

Alur penelitian digunakan mempermudah dan sebagai panduan dalam pelaksanaan penelitian. Berdasarkan Gambar 1. penelitian ini melalui 6 tahapan, meliputi (1) studi literasi, (2) pengumpulan data, (3) perancangan sistem, (4) pembuatan program, (5) pengujian sistem dan yang terakhir (6) analisis uji sistem.



Gambar 1. Diagram blok alur penelitian

2.2 Pemodelan Sistem

Pemodelan sistem dalam penelitian ini digambarkan dalam diagram blok pada Gambar 2. Yang terdiri dari beberapa tahapan, seperti (1) *pre-processing*, (2) ekstraksi fitur menggunakan STFT, dan (3) klasifikasi sinyal menggunakan SVM.



Gambar 2. Diagram blok pemodelan sistem

2.2.1 Input Sinyal Phonocardiogram

Penelitian ini menggunakan data sekunder yang diperoleh dari situs *Physionet*. Rekaman suara jantung bersumber dari beberapa kontributor di seluruh dunia, dikumpulkan secara klinis maupun non-klinis, baik dari subjek sehat maupun pasien patologis. Pada penelitian ini, dipilih *dataset* dengan data sebanyak 2141 *files* rekaman suara jantung manusia, dengan durasi dari 5 hingga 120 detik. Jumlah data yang berlabel normal sebanyak 1958 *files* suara, dan abnormal sebanyak 183 *files*, seluruh *files* rekaman disimpan dalam format *.wav* serta menggunakan frekuensi sampling 2000 Hz [15,16].

Rekaman suara jantung dikumpulkan dari berbagai lokasi di tubuh. Empat lokasi tersebut adalah daerah aorta, daerah pulmonal, daerah trikuspid dan daerah mitral. Pada *test* dan *training* set, rekaman suara jantung dibagi menjadi dua jenis: rekaman suara jantung normal dan abnormal. Rekaman normal berasal dari subyek sehat dan yang abnormal berasal dari pasien dengan diagnosis jantung yang telah terkonfirmasi. Kondisi abnormal ini meliputi pasien cacat katup jantung dan penyakit arteri koroner. Rekaman suara jantung juga mengandung berbagai *noise*, seperti suara percakapan, gerakan stetoskop, pernapasan, dan usus. Pemrosesan sinyal PCG dilakukan secara otomatis menggunakan program *spyder* dengan bahasa pemrograman *python*.

2.2.2 Preprocessing Data

Pre-processing yang dibagi 2 tahapan yaitu labeling data dan *zero-padding*. Labeling digunakan untuk mengkategorikan sinyal suara jantung normal dan abnormal berdasarkan *file REFERENCE – SQI* yang ada pada folder dataset. Terdapat 2 tipe label yang digunakan, yaitu “-1” yang berarti sinyal jantung normal dan “1” berarti abnormal. Sedangkan, *zero-padding* digunakan untuk menyamakan ukuran *array file* inputan sinyal suara jantung.

2.2.3 Ekstraksi Fitur ShortTime Fourier Transform

Proses ekstraksi fitur melalui dua tahapan, pertama, kalkulasi dari STFT dan yang kedua adalah pemilihan variasi *window w(n)*. Adanya *window* menambah dimensi waktu, sehingga dapat diperoleh analisis frekuensi-waktu. *Short time fourier transform* didefinisikan sebagai [17]:

$$X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n]w[n-m]e^{-j\omega n} \quad (1)$$

Dengan $x[n]$ merupakan sinyal masukan, $w[n]$ merupakan fungsi *window*, n dan m merupakan komponen waktu, serta ω kecepatan sudut. Adapun jenis variasi *window* yang digunakan adalah *Hanning*, *Hamming*, dan *Blackman window*, yang masing-masing fungsi *window* ditunjukkan oleh persamaan berikut.

Hanning Window [17]

$$w[n] = \frac{1}{2} \left(1 - \cos \left(\frac{2\pi n}{N-1} \right) \right) \quad (2)$$

Hamming Window [18]

$$w[n] = 0.54 - 0.46 \cos \left(\frac{2\pi n}{N-1} \right) \quad (3)$$

Blackman Window [17]

$$w[n] = 0.42 + 0.5 \cos \left(\frac{2\pi n}{N-1} \right) + 0.08 \cos \left(\frac{4\pi n}{N-1} \right) \quad (4)$$

Setelah melalui proses kalkulasi, langkah selanjutnya akan diambil nilai STFT, nilai frekuensi dan waktu pada saat sinyal mencapai puncaknya, dan nilai rata-rata amplitudo dari sebuah sinyal suara untuk kemudian akan dilatih dan diuji menggunakan *Support Vector Machine* (SVM).

2.2.4 Klasifikasi Support Vector Machine

Nilai yang didapat dari ekstraksi fitur digunakan pada klasifikasi Metode klasifikasi yang digunakan adalah menggunakan metode *support vector machine* (SVM) dengan input 4 nilai ekstraksi fitur, yaitu nilai STFT, nilai frekuensi dan waktu saat amplitudo tertinggi, dan nilai rata-rata amplitudo pada sebuah sinyal suara. SVM mengolah data yang diperoleh dari ekstraksi fitur dengan menggunakan variasi 3 jenis *kernel*, yaitu *linear*, *rbf*, dan *polynomial* dan variasi nilai C parameter 7 level dengan rentang 0.001, 0.01, 0.1, 1, 10, 100, 1000. Persamaan variasi *kernel* yang digunakan dalam SVM [19]:

Linear

$$K(x_i, x_j) = (x_i, x_j) \quad (5)$$

Polynomial

$$K(x_i, x_j) = (x_i, x_j + r)^d \quad (6)$$

Radial Basis Function

$$K(x_i, x_j) = \exp(-\gamma \|x_i, x_j\|^2) \quad (7)$$

x_i, x_j merupakan pasangan dua data *training*. Parameter C, γ, r, d merupakan konstanta.

2.2.5 Pengukuran Kinerja Klasifikasi

Pengukuran kinerja klasifikasi pada data asli dan data hasil dari model klasifikasi dilakukan dengan menggunakan *K-Fold Cross Validation* untuk digunakan dalam mengestimasi kinerja model, dan *Confusion matrix* untuk digunakan sebagai penguji keakuratan yang sering digunakan dalam menunjukkan hasil klasifikasi terutama pada data *multiclass*.

a. *K-Fold Cross Validation*

Cross validation adalah metode evaluasi model yang digunakan pada pelatihan dengan data terbasas [20]. Total data dibagi secara acak mejadi k subset dengan jumlah yang sama. Satu subset tersebut dibagi menjadi data *training* dan data *testing*. Proses ini dilakukan sebanyak k kali. Pada perilahan ke-*i*, subset *i* akan menjadi data testing. Sedangkan k-1 subset akan menjadi data *training*. Adapun langkah-langkah dalam prosedur sebagai berikut: (1) Membagi data menjadi k bagian dengan ukuran yang sama. (2) Pada data k-1 merupakan data *training* dan bagian lainnya merupakan data *testing*. (3) Pada langkah ini dilakukan berulang sebanyak k setiap kombinasi data *training* dan data *testing* yang berbeda, sehingga semua data akan menjadi data *testing*. Estimasi nilai dari suatu model akhir dapat diperoleh dengan menghitung rata-rata dari nilai akurasi pada setiap iterasi.

b. *Confusion matrix*

Confusion matrix atau yang dikenal dengan tabel kontingensi merupakan uji keakuratan yang sering digunakan dalam menunjukkan hasil klasifikasi terutama pada data *multiclass* [21]. Pada *Confusion matrix* hasil kelas prediski dibandingkan dengan kelas sebenarnya. Semakin rendah error makan semakin bagus tingkat kinerja model.

Tabel 1. Tabel *confusion matrix* yang digunakan untuk uji klasifikasi

Kelas Prediksi Kelas Asli	Prediksi Normal (-1)	Prediksi Abnormal (1)
Kondisi asli Normal (-1)	<i>True Positif (TP)</i>	<i>False Positif (FP)</i>
Kondisi asli Abnormal (1)	<i>False Negatives (FN)</i>	<i>True Negatif (TN)</i>

Parameter yang digunakan untuk pemrosesan data dibagi menjadi 4 persamaan yaitu Sensitifitas (SN), Spesitifitas (SP), Akurasi (ACC), dan *Area Under ROC Curve* (AUC). Persamaan pengukur kinerja klasifikator dapat dituliskan sebagai berikut.

$\text{Sensitifitas} = \frac{TP}{(TP + TN)} = \frac{TP}{T}$	(8)
$\text{Spesitifitas} = \frac{TN}{(TN + FP)} = \frac{TN}{N}$	(9)
$\text{Akurasi} = \frac{TN + TP}{(TN + TP + FN + FP)} = \frac{TN + TP}{P + N}$	(10)
$\text{AUC} = \frac{\text{Sensitivitas} + \text{Spesitivitas}}{2}$	(11)

Untuk menghitung satuan ukuran kinerja dari suatu model berdasarkan *confusion matrix* dengan *True Negative* (TN) merupakan jumlah data pasien yang normal terklasifikasi dengan

benar ke dalam pasien yang normal, *False Negative* (FN) merupakan jumlah data pasien yang berpenyakit terklasifikasi ke dalam pasien yang normal, *True Positive* (TP) adalah jumlah data pasien yang berpenyakit terklasifikasi dengan benar ke dalam pasien yang berpenyakit, dan *False Positive* (FP) merupakan jumlah data pasien yang normal terklasifikasi ke dalam pasien yang berpenyakit.

2.3 Pengujian Sistem


Pengujian sistem dilakukan dengan menginput dataset suara jantung atau hasil rekaman PCG sebanyak 2141 data, yang akan dibagi kedalam data *training* dan data *testing* untuk ditampilkan hasil klasifikasinya. Proses pengujian akan melewati dua metode yang digunakan yaitu ekstraksi fitur menggunakan *shorttime fourier transform* dan klasifikasi *support vector machine*. Pengujian juga akan memasukkan variasi nilai-nilai yang berpengaruh terhadap hasil pengujian seperti variasi *window* pada STFT, dan variasi jenis *kernel* serta variasi nilai *C* parameter dari SVM.

3. HASIL DAN PEMBAHASAN

Bagian ini menguraikan hasil pengujian metode klasifikasi STFT dan SVM serta pembahasan terhadap hasil eksperimen yang telah dilakukan. Pengujian menggunakan dataset PCG yang disediakan oleh physionet, sebanyak 2141 data rekaman suara jantung dalam keadaan normal dan abnormal. Seluruh data suara jantung pada dataset ini menggunakan frekuensi sampling 22.050 Hz.

3.1 Analisis Hasil Uji Sinyal PCG


Pengujian pertama mengamati bentuk sinyal jantung normal dan abnormal. Karakteristik kondisi jantung dalam sinyal PCG direpresentasikan dengan suara “lub” dan “dub” yang menandakan proses mekanik katup jantung. Kondisi jantung normal hanya memiliki dua suara yakni S1 dan S2 sedangkan kondisi jantung abnormal memiliki empat komponen suara yakni S1, S2, S3, dan S4. Karakteristik kondisi jantung berdasarkan sinyal PCG ditampilkan pada gambar 3 dan gambar 4. Gambar 3 menampilkan sinyal PCG jantung normal (*file e00550*) dalam durasi 2 detik. Sedangkan, gambar 4 menampilkan sinyal PCG jantung abnormal (*file e01013*) yang telah dipotong dengan durasi waktu 2 detik.



Gambar 3. Sinyal PCG Normal

Kondisi jantung normal memiliki dua suara utama yang menandakan proses buka-tutup katup jantung. Suara S1 terdengar saat penutupan katup atrioventrikular yakni katup mitral dan katup trikuspidal. Penutupan katup atrioventrikular mengawali kondisi sistol. Sementara itu, suara jantung kedua (S2) terjadi akibat penutupan katup semilunar yakni katup aorta dan katup


pulmonal. Penutupan katup semilunar menandakan permulaan kondisi diastol. Gambar 4. menunjukkan sebuah sinyal PCG pada kondisi jantung abnormal. Sinyal jantung PCG pada kondisi abnormal akan menghasilkan 4 buah suara, yaitu S1, S2, S3, S4. Suara jantung ketiga muncul diantara S1 dan S2, oleh karena itu kondisi ini juga disebut dengan murmur sistolik. Murmur sistolik terjadi akibat adanya osilasi darah antara dinding aorta dan ventrikular. Suara jantung keempat (S4) disebut juga dengan murmur diastolik karena suara jantung keempat muncul setelah suara jantung kedua dan pertama atau selama proses diastolik. S4 disebabkan oleh adanya turbulensi dari ejeksi darah.




Gambar 4. Sinyal PCG Abnormal

3.2 Analisis Ekstraksi Fitur Sinyal PCG


Penggunaan STFT sebagai ekstraksi fitur berfungsi untuk mendapatkan fitur frekuensi dan waktu secara bersamaan. Representasi spektrogram yang memuat informasi frekuensi, waktu, dan magnitudo sinyal dipergunakan sebagai fitur-fitur dalam tahapan klasifikasi. Gambar 5 menampilkan sinyal PCG beserta dengan spektrogram dalam domain frekuensi waktu.




(a)



(c)



(b)




(d)

Gambar 5 (a) Sinyal PCG pada kondisi normal dan (b) spektrogram hasil ekstraksi sinyal PCG normal menggunakan variasi *Hamming Window*, (c) Sinyal PCG kondisi abnormal dan (d) spektrogram hasil ekstraksi sinyal PCG abnormal menggunakan variasi *Hamming Window*.

Spektrogram dalam gambar 5 (b) menunjukkan sinyal PCG kondisi normal yang direpresentasikan dalam domain frekuensi-waktu. Penentuan posisi magnitudo yang paling tinggi dari S1 ditandai dengan lingkaran hitam. Nilai amplitudo tertinggi dalam bagian ini sebesar adalah 51.15 dB pada gambar ditunjukkan oleh bias warna merah yang pada index berada pada rentang lebih dari 50dB. Waktu saat amplitudo tertinggi adalah 0.34s hal ini ditunjukkan oleh letak lingkaran hitam yang berada pada sumbu x dengan rentang waktu 0s-0.5s, dan frekuensi saat amplitudo tertinggi adalah 129.199 Hz hal ini ditunjukkan oleh letak lingkaran hitam yang berada pada sumbu y dengan rentang frekuensi pada 128-256 Hz. Dari nilai-nilai tersebut menunjukkan bahwa frekuensi yang bernilai 129.199 Hz telah sesuai dengan teori yang menyebutkan bahwa frekuensi jantung normal berada pada rentang 20-200 Hz [22].

Gambar 5(d) menunjukkan sinyal suara jantung (PCG) abnormal. Area dilingkari menunjukkan posisi S1 dengan nilai amplitudo yang didapatkan sebesar adalah 36.84 dB pada gambar ditunjukkan oleh bias warna putih yang pada index berada pada rentang lebih dari 30dB. Waktu saat amplitudo tertinggi adalah 1.69 s hal ini ditunjukkan oleh letak lingkaran hitam yang berada pada sumbu x dengan rentang waktu 1.5s-2s, dan frekuensi saat amplitudo tertinggi adalah 215.34 Hz hal ini ditunjukkan oleh letak lingkaran hitam yang berada pada sumbu y dengan rentang frekuensi pada 128-256 Hz. Dari nilai-nilai tersebut menunjukkan bahwa frekuensi yang bernilai 215.34 Hz telah sesuai dengan teori yang menyebutkan bahwa frekuensi jantung abnormal berada pada rentang 20-400 Hz [22]. Kondisi abnormal memiliki S1 yang lebih rendah amplitudonya dibandingkan dengan kondisi normal dan frekuensi yang lebih tinggi dari kondisi normal.



Gambar 6: (a) Spektrogram hasil ekstraksi sinyal PCG normal menggunakan variasi *Hanning Window*, (b) Spektrogram hasil ekstraksi sinyal PCG abnormal menggunakan variasi *Hanning Window*, (c) Spektrogram hasil ekstraksi sinyal PCG normal menggunakan variasi *Blackman Window*, (d) Spektrogram hasil ekstraksi sinyal PCG abnormal menggunakan variasi *Blackman Window*

Variasi jenis window berdampak terhadap hasil ekstraksi fitur STFT dimana gambar 6 (a) dan (c) merupakan spektrogram PCG normal dengan dua *window* yang berbeda. Sedangkan gambar 6

(b) dan (d) merupakan spektrogram PCG abnormal dengan dua *window* yang berbeda. Meskipun penggunaan *window* yang berbeda menghasilkan spektrogram yang hampir serupa, nilai amplitudo masing-masing spektrogram berbeda. Spektrogram pada gambar 6 (a) memiliki amplitudo sebesar 50.78 dB, sedangkan untuk gambar 6 (c) memiliki amplitudo sebesar 49.56 dB. Meskipun amplitudo masing-masing spektrogram berbeda, waktu dan frekuensi pada titik amplitudo tertinggi memiliki nilai yang sama akibat dari penggunaan *file* suara yang sama, yaitu sebesar 0.348 s dan frekuensi saat amplitudo tertinggi adalah 129.199 Hz. Spektrogram PCG abnormal juga dipengaruhi oleh penggunaan jenis *window*. Spektrogram pada Gambar 6 (b) dan (d), menunjukkan hasil yang serupa dengan variasi jenis *window* berpengaruh pada nilai amplitudo yang dihasilkan yaitu sebesar 36.72 dB untuk Gambar 6 (b) sedangkan untuk Gambar 6 (d) menghasilkan nilai amplitudo sebesar 36.29 dB. Waktu saat amplitudo tertinggi adalah 1.6021 s dan frekuensi saat amplitudo tertinggi adalah 172.2656 Hz. Waktu dan frekuensi saat amplitudo tertinggi memiliki nilai yang sama akibat dari penggunaan *file* suara yang sama, yaitu sebesar 0.348 s dan frekuensi saat amplitudo tertinggi adalah 129.199 Hz.

Perbedaan mendasar antara spektrogram *window hamming*, *hanning*, dan *blackman* terlihat pada bias warna biru pada sinyal normal dan bias warna hitam pada sinyal abnormal yang membatasi puncak dari masing masing sinyal. Pada spektrogram *hamming*, frekuensi tertinggi sinyal baik normal maupun abnormal, terlihat bias warna yang melewati batas yang berada pada titik 1024 Hz. Sementara pada *window hanning* dan *blackman* seluruh frekuensi terhenti pada batas frekuensi *window*.

Tabel 2. Perbandingan nilai ekstraksi fitur kondisi jantung normal pada masing-masing *window*

Jenis <i>Window</i>	Fitur					
	Jantung normal			Jantung abnormal		
	Amplitudo tertinggi (dB)	Frekuensi (Hz)	Waktu (s)	Amplitudo tertinggi (dB)	Frekuensi (Hz)	Waktu (s)
<i>Hamming</i>	51.15	129.199	0.34	36.84	215.33	1.69
<i>Hanning</i>	50.78	129.199	0.34	36.72	215.33	1.69
<i>Blackman</i>	49.56	129.199	0.34	36.29	215.33	1.69

Penggunaan jenis *window* yang berbeda memberikan spektrogram yang berbeda terutama dari parameter magnitudo spektrogram. Tabel 2 menunjukkan bahwa variasi *window* berpengaruh pada hasil nilai amplitudo tertinggi *file* suara jantung yang sama. Namun, variasi *window* tidak berpengaruh pada frekuensi dan waktu. Setelah didapatkan amplitudo tertinggi, dan letak frekuensi dan waktu pada amplitudo tertinggi untuk masing-masing variasi *window*, nilai ekstraksi ciri yang didapatkan selanjutnya adalah nilai kalkulasi STFT. Hasil nilai STFT disajikan dalam bentuk tabel berikut.

Tabel 3. Perbandingan Nilai STFT kondisi jantung normal dan abnormal pada masing-masing *window*

Jenis <i>Window</i>	Nilai STFT	
	Sinyal PCG Normal	Sinyal PCG Abnormal
<i>Hamming</i>	130,540.92	4839.925293
<i>Hanning</i>	119,912.07	4704.322754
<i>Blackman</i>	90,472.88	4264.213867

Berdasarkan tabel 3 setiap variasi jenis *window* memiliki nilai yang berbeda, hal ini sama dengan hasil nilai amplitudo. Nilai STFT menjadi nilai yang merepresentasikan nilai dari ekstraksi fitur dalam domain waktu dan frekuensi sementara itu amplitudo merepresentasikan kekuatan sinyal yang didalamnya terdapat nilai waktu dan frekuensi. Nilai-nilai pada tabel 2 hingga tabel 3 nantinya akan dijadikan sebagai nilai masukkan untuk klasifikasi pada *Support Vector Machine* (SVM).

3.3 Analisis Klasifikasi Sinyal PCG Normal dan Abnormal

Tahapan pengklasifian terdiri dari dua tahap yakni tahap *training* dan *testing*. Pembagian data *training* dan *testing* menggunakan *K-Fold Cross Validation* dengan nilai parameter $k = 10$. Permasalahan yang diangkat pada penelitian ini adalah klasifikasi kondisi jantung dengan 4 parameter dari hasil ekstraksi menggunakan *short-time fourier transform* yang meliputi nilai STFT, amplitudo, waktu, dan frekuensi saat amplitudo tertinggi. Hasil ekstraksi akan diklasifikasikan ke dalam kelas yang meliputi “normal” dan “abnormal”. Dataset yang digunakan memiliki 1958 *file* atau sekitar 90% suara normal, dan 183 atau sekitar 10% suara abnormal. Jumlah data abnormal yang lebih rendah dibandingkan dengan data normal dengan rasio kelas mayoritas dibandingkan dengan kelas minoritas adalah 9:1 yang menunjukkan adanya imbalance data. Pengubahan nilai parameter C dapat mengubah toleransi dari *hyperplane* sehingga dapat mencegah kesalahan klasifikasi kelas minoritas karena dominasi dari kelas mayoritas. Selain itu, fungsi *kernel* digunakan untuk mengolah data yang tidak dapat dipisahkan oleh garis *hyperplane* secara langsung. Fungsi *kernel* akan mengubah dimensi data yang rendah menjadi data berdimensi lebih tinggi. Masing-masing variasi *kernel* akan dievaluasi performanya menggunakan parameter sensitivitas, spesitifitas, dan AUC (*area under ROC curve*). Kami menggunakan 3 macam *kernel* yaitu RBF, *linear*, dan *polynomial*.

Penggunaan *window hamming*, *hanning* dan *blackman* menghasilkan nilai performa yang berbeda seperti ditampilkan dalam tabel 4. Tipe *window Hamming* memiliki kinerja lebih baik dibandingkan dengan tipe *Hanning* atau *Blackman* baik untuk nilai sensitivitas, spesitifitas, dan AUC. Berdasarkan hasil pengujian masing-masing *windows* dapat disimpulkan bahwa *hamming window* memiliki hasil AUC terbaik dengan nilai sebesar 75,85%. Penggunaan jenis *window* yang berbeda memiliki pengaruh terhadap hasil evaluasi pada klasifikator yang digunakan. Berdasarkan hasil terbaik yang didapatkan oleh *Hamming Window*, maka percobaan pada masing-masing *kernel* menggunakan hasil ekstraksi fitur dari *Hamming Window* sebagai masukkannya.

Tabel 4. Tingkat kinerja terbaik pada masing-masing variasi *window*

Jenis <i>Window</i>	Sensitivitas	Spesitifitas	AUC
<i>Hamming</i>	62.24%	89,47%	75,85%
<i>Hanning</i>	58.67%	84,21%	71,44%
<i>Blackman</i>	60.71%	73,68%	67,19%

1) Analisis pengaruh nilai parameter C terhadap kinerja model

Parameter evaluasi kinerja akurasi yang umum digunakan untuk mengukur performa model klasifikasi kurang baik untuk analisis data tak seimbang. Kesalahan klasifikasi data minoritas sering terjadi saat menggunakan parameter akurasi karena pengklasifikasian data all-positive atau all-negative dapat mencapai tingkat klasifikasi yang sangat baik. Parameter pengukuran yang diambil dari kurva *Receiver Operating Characteristics* (ROC) dapat digunakan sebagai parameter alternatif yang lebih baik untuk mengevaluasi model. Salah satu parameter kinerja yang sering digunakan yakni *Area Under ROC Curve* (AUC). AUC dihitung dari nilai sensitivitas dan spesitifitas sehingga mampu menggambarkan kesalahan klasifikasi data positif dan data negative secara bersamaan. Pengamatan pengaruh nilai parameter C terhadap kinerja model menggunakan

nilai AUC sebagai patokan utama. Nilai AUC yang tertinggi merupakan model dengan kinerja terbaik. Tabel 5 menampilkan hasil evaluasi kinerja model dengan variasi nilai parameter C dan kernel.

Tabel 5. Hasil evaluasi kinerja pada masing-masing nilai parameter C dan kernel

Nilai Parameter C	Jenis Kernel	Sensitivitas	Spesifitas	AUC
0.001	Linear	100%	0%	0.5
	Polynomial	100%	0%	0.5
	RBF	100%	0%	0.5
0.01	Linear	86.22%	10.53%	0.48
	Polynomial	37.24%	94.74%	0.66
	RBF	29.59%	89.47%	0.60
0.1	Linear	33.67%	100.00%	0.67
	Polynomial	52.04%	94.74%	0.73
	RBF	49.49%	94.74%	0.72
1	Linear	53.06%	78.95%	0.66
	Polynomial	58.67%	84.21%	0.71
	RBF	54.08%	100.00%	0.77
10	Linear	61.22%	73.68%	0.67
	Polynomial	63.27%	89.47%	0.76
	RBF	66.33%	68.42%	0.67
100	Linear	59.18%	84.21%	0.72
	Polynomial	61.73%	78.95%	0.70
	RBF	68.37%	94.74%	0.82
1000	Linear	57.14%	89.47%	0.73
	Polynomial	66.33%	89.47%	0.78
	RBF	70.92%	94.74%	0.83

Berdasarkan Tabel 5 metode SVM dengan menggunakan *kernel* RBF dengan C sebesar 1000 memiliki nilai AUC tertinggi yaitu sebesar 0.83, hasil tersebut mengindikasikan hasil yang sangat baik untuk sebuah performansi klasifikator. Nilai AUC terendah didapatkan pada *kernel-kernel* dengan C sebesar 0.001, dengan nilai sebesar 50%, hasil tersebut mengindikasikan hasil yang paling buruk untuk nilai evaluasi dari sebuah performa klasifikator. Alasan rendahnya nilai AUC pada C sebesar 0.001 dikarenakan nilai C yang sangat kecil, yang mengakibatkan terjadinya banyak misklasifikasi dari data yang diproses. Model dengan nilai parameter C sebesar 1000 apat mengklasifikasikan data yang sangat tidak seimbang secara baik. Pengaruh variasi parameter C dapat disimpulkan bahwa ketika nilai parameter terlalu besar dapat terjadi peristiwa *overfitting*, namun jika terlalu kecil juga dapat mengakibatkan peristiwa *underfitting*.

2) Analisis pengaruh kernel terhadap kinerja model

Perubahan kernel berpengaruh terhadap kinerja model seperti yang ditampilkan pada tabel 5. Nilai parameter C sebesar 1000 menghasilkan nilai kinerja AUC terbaik sehingga pengujian kinerja akurasi model diamati dengan nilai parameter C konstan. Berdasarkan analisis *kernel* terbaik untuk pengklasifikasian menggunakan parameter AUC, langkah selanjutnya adalah melakukan analisis hasil akurasi pada *kernel-kernel* tersebut untuk mendapatkan akurasi terbaik. Berdasarkan Tabel 6 nilai AUC terbaik pada masing-masing *window* dikelompokkan kembali untuk dihitung akurasinya didapatkan bahwa hasil akurasi terbaik didapatkan *window* RBF dengan

tingkat akurasi sebesar 72.40% nilai ini selaras dengan nilai AUC dimana *kernel* RBF juga mendapatkan nilai terbaik.

Tabel 6. Hasil Nilai Akurasi pada Kernel Terbaik berdasarkan nilai AUC

<i>Kernel</i>	Besar C Parameter	AUC	Akurasi
<i>Linear</i>	1000	0.73	62.73%
<i>Polynomial</i>		0.78	66.56%
RBF		0.83	72.40%

Tabel 7 menampilkan *confusion matrix* yang digunakan untuk menghitung nilai parameter di tabel 6. Tabel 7 membuktikan hasil *kernel* RBF lebih baik daripada hasil *kernel* lainnya, dimana pada *kernel* RBF memiliki banyak data normal 133, dan pada kondisi abnormal *kernel* RBF sukses memprediksi 18 suara abnormal.

Tabel 7 Confusion matrix pada Kernel Terbaik

Jenis <i>Kernel</i>	<i>Confusion matrix</i>			
<i>Linear</i>	Kelas Sebenarnya		Kelas Prediksi	
			Normal (-1)	Abnormal (1)
		Normal (-1)	116	80
		Abnormal (1)	3	16
<i>Polynomial</i>	Kelas Sebenarnya		Kelas Prediksi	
			Normal (-1)	Abnormal (1)
		Normal (-1)	119	77
		Abnormal (1)	2	17
RBF	Kelas Sebenarnya		Kelas Prediksi	
			Normal (-1)	Abnormal (1)
		Normal (-1)	133	63
		Abnormal (1)	1	18

4. KESIMPULAN

Ekstraksi ciri yang dilakukan pada suara jantung menggunakan metode *short time fourier transform*, bertujuan untuk mengambil fitur suara yang terdapat pada suara jantung, yaitu nilai STFT, rata-rata amplitudo, besaran waktu dan frekuensi saat amplitudo tertinggi. Nilai STFT diekstraksi untuk merepresentasikan nilai dari kinerja metode ekstraksi fitur pada masing-masing variasi jenis *window*, sedangkan amplitudo diekstraksi untuk merepresentasikan sinyal suara jantung yang didalamnya terdapat informasi frekuensi dan waktu. Hasil ekstraksi ciri terbaik ditunjukkan oleh *Hamming Window* berdasarkan evaluasi menggunakan AUC. Proses klasifikasi suara jantung normal dan abnormal pada *support vector machine* (SVM) menggabungkan beberapa parameter uji seperti variasi jenis *kernel* dan nilai parameter C, jenis variasi *kernel* yang digunakan adalah *kernel linear*, *polynomial*, dan RBF. Nilai parameter C mampu membuat SVM membentuk *hyperplane* yang memisahkan data normal dan abnormal secara lebih akurat, dengan nilai variasi 7 level, yaitu 0.0001, 0.001, 0.01, 1, 10, 100, 1000. Dengan hasil terbaik diperoleh oleh *kernel* RBF dengan nilai C parameter sebesar 1000 menghasilkan nilai AUC sebesar 0.83 dengan rata-rata akurasi sebesar 72.4%.

UCAPAN TERIMA KASIH

Alhamdulillah rabbil 'alamin, segala puji dan syukur kehadiran Allah SWT yang telah melimpahkan kasih dan sayang-Nya, sehingga penulis dapat menyelesaikan jurnal yang berjudul “Klasifikasi Sinyal *Phonocardiogram* Menggunakan Metode *Short Time Fourier Transform* Dan *Support Vector Machine*” sesuai dengan target yang telah ditetapkan. Selain itu penulis juga mengucapkan terima kasih kepada pihak-pihak yang telah memberi dukungan baik material maupun nonmaterial terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] World Health Organization. World health statistics 2018: monitoring health for the SDGs, sustainable development goals. Geneva: World Health Organization; 2018.
- [2] Kementerian Kesehatan RI. Hasil Utama RISKESDAS 2018. Indonesia: Kementerian Kesehatan RI, Badan Penelitian dan Pengembangan Kesehatan; 2018.
- [3] Khansa A, Partiningrum DL. HUBUNGAN ANTARA LAMA HIPERTENSI DAN GAMBARAN ELEKTROKARDIOGRAM HIPERTROFI VENTRIKEL KIRI DAN INFARK MIOKARD LAMA 2018;7:15.
- [4] Sepehri AA, Kocharian A, Janani A, Gharehbaghi A. An Intelligent Phonocardiography for Automated Screening of Pediatric Heart Diseases. *J Med Syst* 2016;40:16. <https://doi.org/10.1007/s10916-015-0359-3>.
- [5] Chowdhury TH, Poudel KN, Hu Y. Time-Frequency Analysis, Denoising, Compression, Segmentation, and Classification of PCG Signals 2020;8:9.
- [6] Purwanto A, Sumarna, Agustika DK. EKSTRAKSI KOMPONEN FREKUENSI PADA ISYARAT DETAK JANTUNG DENGAN SHORT TIME FOURIER TRANSFORM (STFT). *Sains Dasar* 2016;5:6.
- [7] Hasanah H. KLASIFIKASI SINYAL ELEKTROKARDIOGRAF (EKG) DENGAN SHORT TIME FOURIER TRANSFORM (STFT) DAN BACKPROPAGATION 2015;9:15.
- [8] Kao W-C, Wei C-C, Liu J-J, Hsiao P-Y. Automatic heart sound analysis with short-time Fourier transform and support vector machines. 2009 52nd IEEE Int. Midwest Symp. Circuits Syst., Cancun, Mexico: IEEE; 2009, p. 188–91. <https://doi.org/10.1109/MWSCAS.2009.5236120>.
- [9] Noble WS. What is a support vector machine? *Nat Biotechnol* 2006;24:1565–7. <https://doi.org/10.1038/nbt1206-1565>.
- [10] Daso F, Puspasari I, Jusak. ANALISIS SINYAL SUARA JANTUNG DENGAN MENGGUNAKAN ANALISIS SPEKTRUM n.d.:9.
- [11] Puspasari I. Analisis Non-Stasioner pada Deteksi Non-Invasive Sinyal Suara Jantung Koroner. *J Nas Tek Elektro Dan Teknol Inf JNTETI* 2015;4. <https://doi.org/10.22146/jnteti.v4i2.148>.
- [12] Lubaib P, Muneer KVA. The Heart Defect Analysis Based on PCG Signals Using Pattern Recognition Techniques. *Int Conf Emerg Trends Eng Sci Technol ICETEST - 2015* 2016;24:1024–31. <https://doi.org/10.1016/j.protcy.2016.05.225>.

- [13] Wang Y, Sun B, Yang X, Meng Q. Research on heart sound recognition based on support vector machine. 2017 Chin. Autom. Congr. CAC, Jinan: IEEE; 2017, p. 62–5. <https://doi.org/10.1109/CAC.2017.8242737>.
- [14] Islam MdR, Hassan MdM, Raihan M, Datto SK, Shahriar A, More A. A Wireless Electronic Stethoscope to Classify Children Heart Sound Abnormalities. 2019 22nd Int. Conf. Comput. Inf. Technol. ICCIT, Dhaka, Bangladesh: IEEE; 2019, p. 1–6. <https://doi.org/10.1109/ICCIT48885.2019.9038406>.
- [15] Liu C, Springer D, Li Q, Moody B, Juan RA, Chorro FJ, et al. An open access database for the evaluation of heart sound algorithms. *Physiol Meas* 2016;37:2181–213. <https://doi.org/10.1088/0967-3334/37/12/2181>.
- [16] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 2000;101. <https://doi.org/10.1161/01.CIR.101.23.e215>.
- [17] Tandiallo JM, Rasmana ST, Puspasari I. IDENTIFIKASI SUARA MANUSIA BERDASARKAN JENIS KELAMIN MENGGUNAKAN EKSTRAKSI FITUR SHORT TIME FOURIER TRANSFORM. *JCONES - Journal of Control and Network Systems* 2016;5:177–83.
- [18] Cadum SA, Susanto A, Brotopuspito KS. TRANSFORM FOURIER CEPAT MATEMATIS UNTUK MENGANALISIS SPEKTRUM FREKUENSI LINIER SINYAL TUTUR. *Jur Tek Elektro Fak Tek Univ Gadjah Mada* 2004;2:31–40.
- [19] Ritonga AS, Purwaningsih ES, Putra UW. PENERAPAN METODE SUPPORT VECTOR MACHINE (SVM) DALAM KLASIFIKASI KUALITAS PENGELASAN SMAW (SHIELD METAL ARC WELDING) 2018:9.
- [20] Hermanto H, Mustopa A, Kuntoro AY. ALGORITMA KLASIFIKASI NAIVE BAYES DAN SUPPORT VECTOR MACHINE DALAM LAYANAN KOMPLAIN MAHASISWA. *JITK J Ilmu Pengetah Dan Teknol Komput* 2020;5:211–20. <https://doi.org/10.33480/jitk.v5i2.1181>.
- [21] Kulkarni A, Chong D, Batarseh FA. 5 - Foundations of data imbalance and solutions for a data democracy. In: Batarseh FA, Yang R, editors. *Data Democr.*, Academic Press; 2020, p. 83–106. <https://doi.org/10.1016/B978-0-12-818366-3.00005-8>.
- [22] Tagashira M, Nakagawa T. Biometric Authentication Based on Auscultated Heart Sounds in Healthcare. *IAENG Int J Comput Sci* 2020;47.