

KLASIFIKASI JENIS BURUNG BERDASARKAN SUARA MENGGUNAKAN ALGORITME *SUPPORT VECTOR MACHINE*

Annisa Miftahul Afida

Jurusan Matematika, FMIPA, Universitas Negeri Surabaya
e-mail : annisaafida@mhs.unesa.ac.id

Abstrak

Burung merupakan salah satu hewan yang perlu dilindungi karena beberapa jenis telah punah. Untuk mengatasi kepunahan tersebut diperlukan upaya konservasi karena tidak semua habitat burung dapat dijangkau oleh manusia. Suara burung merupakan salah satu penanda yang khas untuk menandakan adanya kehidupan burung. Dengan teknologi informasi dan komunikasi, manusia dapat mengenali jenis burung berdasarkan suara khas burung. Proses klasifikasi berdasarkan suara merupakan salah satu permasalahan yang dapat diselesaikan dengan *Machine Learning*. Proses reduksi *noise* diperlukan untuk menghilangkan suara yang tidak diperlukan pada rekaman suara seperti angin dan hujan. Proses reduksi *noise* dengan Transformasi Wavelet menghasilkan sinyal suara yang lebih jernih dengan hasil nilai PSNR sebesar 4,2890. Wavelet. Pada penelitian ini dilakukan klasifikasi jenis burung berdasarkan suara menggunakan salah satu algoritme *machine learning*, yaitu *Support Vector Machine (SVM)* dengan kernel *Heavy Tailed RBF* dan rasio pemisahan data 7:3. Akurasi yang dihasilkan dari penelitian ini adalah 77,00% didapatkan dari penggunaan parameter $c = 10.000$ dan $\epsilon = 1.00E-09$

Kata kunci: Klasifikasi Suara Burung, Transformasi Wavelet, Reduksi *Noise*, *Support Vector Machine*

Abstract

Birds are one of the animals that need to be protected because of some extinct species. To solve this problem, conservation are needed because not all bird habitats can be reached by humans. Bird sound was one of the unique markers to indicate the existence of bird life. With technology, information, and communication, human could identify bird species by its sound. The classification process based sound is one of the problems that can be solved by Machine Learning. The noise reduction process is needed to remove noise that is not needed like wind and rain. Noise Reduction using Wavelet Transform result is sound signal more cleaner with PSNR value 4,2890. The classification of bird species is based on sound using one of the machine learning algorithms, Support Vector Machine (SVM) with Heavy Tailed RBF kernel with ratio 7:3. The accuracy produced from this study was 77,00% obtained from the use of parameters namely $c = 10.000$ and $\epsilon = 1.00E-09$.

Keywords : Bird Species Classification, Wavelet Transform, Noise Reduction, Support Vector Machine

1. PENDAHULUAN

Antara tahun 1973 (tahun dibuatnya undang-undang tentang jenis hewan langka) sampai tahun 1990, tercatat 26 jenis hewan punah (Upadhyay, Rai and Iyengar 2001). Salah satu jenis tersebut merupakan jenis burung yang pada tahun 2018 tercatat bahwa 8 burung punah selama satu dekade terakhir (Gibbens, 2018). Beragam faktor dapat menyebabkan jenis burung punah, salah satunya adalah hilangnya habitat burung. Mendeteksi keberadaan burung melalui habitatnya merupakan salah satu langkah awal untuk menentukan upaya konservasi yang perlu dilakukan. Oleh sebab itu, diperlukan metode untuk mengklasifikasikan jenis burung melalui habitatnya sebagai salah satu upaya konservasi jenis burung yang perlahan mulai mengalami kepunahan.

Burung memiliki habitat yang beranekaragam, antara lain hutan, perkebunan, padang rumput, perairan dan lain-lain. Penyebaran jenis burung dipengaruhi oleh kesesuaian lingkungan tempat hidup burung yang meliputi adaptasi burung terhadap perubahan lingkungan, kompetisi, dan seleksi alam (Alikodra 2002). Beberapa habitat burung dapat dijangkau oleh manusia, namun kemampuan manusia dalam menjangkau habitat burung masih terbatas. Suara burung merupakan salah satu penanda yang khas untuk menandakan adanya kehidupan burung.

Dengan teknologi informasi dan komunikasi, manusia dapat mengenali jenis burung yang ditemuinya dengan suara khas tersebut. Saat ini penelitian mengenai klasifikasi jenis burung berdasarkan suara semakin meningkat, antara lain klasifikasi burung berdasarkan suaranya (Raghuram, Chavan, Belur, & Koolagudi, 2016), klasifikasi suara

burung menggunakan CNN (Tóth & Czeba, 2016) dan Identifikasi Jenis Burung Berdasarkan Suara (Elias Sprengel, Jaggi, Kilcher, & Hofmann, 2016).

Machine Learning merupakan proses yang mencakup berbagai macam proses yang sulit yang bertujuan mendapatkan pengetahuan atau pemahaman atau ketrampilan dalam belajar (Nilsson, 2005). Klasifikasi jenis burung berdasarkan suara merupakan salah satu permasalahan yang dapat diselesaikan menggunakan *Machine Learning* yang meliputi ekstraksi fitur suara dan bagian klasifikasi (Fagerlund, 2007). Suara burung dapat diperoleh dari rekaman suara yang direkam di habitatnya. Sayangnya, rekaman suara jenis burung yang dihasilkan sering kali bercampur dengan suara lain, seperti suara angin dan hujan. Oleh sebab itu, sebelum melakukan klasifikasi jenis burung berdasarkan suaranya diperlukan proses reduksi *noise* yang bertujuan untuk menghasilkan rekaman suara burung yang dibutuhkan. Sinyal suara inilah yang akan diakuisisi ke dalam data numerik berupa vektor dan akan melalui proses ekstraksi ciri yang akan digunakan untuk klasifikasi jenis burung. Dalam proses klasifikasi dengan *Machine Learning* akan diberikan data pelatihan, dimana data tersebut akan digunakan sebagai landasan untuk proses pengenalan.

Dalam penelitian ini untuk mengklasifikasi jenis burung berdasarkan suara digunakan salah satu algoritma *machine learning*, yaitu *Support Vector Machine* (SVM). SVM merupakan salah satu metode yang telah banyak digunakan untuk pengenalan pola. Pada proses audio, SVM digunakan untuk pembagian segmen fonetis, pengenalan suara dan klasifikasi suara secara umum. Salah satu keunggulan dari SVM adalah akurasi yang tinggi dan lebih unggul dalam menggeneralisasikan dibanding metode lain (Fagerlund, 2007). Metode *machine learning* ini bertujuan untuk menemukan *hyperplane* terbaik yang memisahkan dua buah *class* pada ruang input (Liu, 2011).

2. KAJIAN TEORI

Suara Burung

Suara burung merupakan salah satu penanda khas adanya keberadaan burung (Raghuram dkk., 2016). Populasi burung Kicauan burung yang cepat dan bervariasi mengakibatkan sinyal suara burung memiliki amplitudo yang bervariasi, sehingga sinyal suara burung merupakan sinyal non-stationer (Priyadarshani dkk., 2016). Suara burung memiliki rentang frekuensi yang bervariasi. Lima jenis burung yang diklasifikasi pada artikel ini adalah jenis burung berukuran kecil yang memiliki rentang frekuensi kicauan 0,5-11,4 kHz.

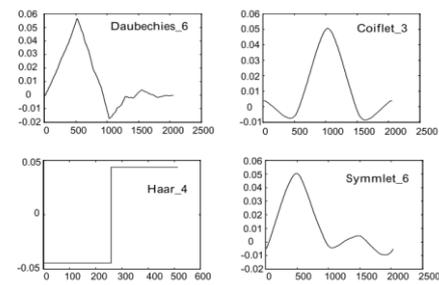
Transformasi Wavelet

Transformasi Wavelet merupakan algoritme yang dapat diterapkan pada analisis sinyal non-stationer. Berbeda dengan STFT yang menggunakan sebuah window untuk menganalisis seluruh sinyal, Transformasi wavelet menggunakan *short window* pada frekuensi tinggi dan *long window* pada frekuensi rendah (Merry,

2011). Selain itu transformasi wavelet telah diaplikasikan pada banyak bidang, antara lain untuk kompresi data, deteksi fitur, dan reduksi *noise*. Analisis yang digunakan wavelet adalah menghitung korelasi antara sinyal dan fungsi mother wavelet $\psi(t)$ yang disebut dengan mother wavelet (Priyadarshani dkk., 2016).

Transformasi wavelet menghasilkan energi citra yang terkonsentrasi pada sebagian kecil koefisien transformasi dan kelompok lain yang mengandung detail. Pose transformasi wavelet dapat dilakukan dengan konvolusi atau pererataan dan pengurangan secara berulang. Proses pererataan dan pengurangan berulang tidak hanya memiliki kompleksitas perhitungan yang lebih rendah, tetapi juga hanya membutuhkan sedikit memori (Zhang dkk., 2016).

Mother wavelet memiliki beberapa jenis antara lain Daubachies, Haar, Symlet, Coiflet, Mexican Hat dan Morlet yang ditunjukkan pada Gambar 1.



Gambar 1. Beberapa jenis wavelet
(Sumber : Graps, 2004)

Salah satu jenis Transformasi Wavelet adalah Discrete Wavelet Transform (DWT). DWT merupakan jenis transformasi wavelet yang menggunakan wavelet ortogonal yang saling ditentukan oleh parameter skala (a) dan translasi (b). Pada domain diskrit, parameter skala dan translasi didiskritkan sebagai $a = a_0^m$ dan $b = nb_0^m$, dengan $a_0 (> 1)$ dan $b_0 (> 0)$ adalah nilai bilangan riil (Graps, 2004). m dan n merupakan nilai bilangan bulat positif. Persamaan DWT didefinisikan sebagai :

$$DWT_{\psi} f(m, n) = \sum_k f(k) \psi_{m,n}^*(k) \quad (1)$$

DWT mendekomposisi sinyal menjadi *subband* dengan *bandwidth* yang meningkat secara linear dengan frekuensi (Singh, 2014). Dalam kasus transformasi dyadic dengan $a_0 = 2$ dan $b_0 = 1$, menghasilkan penskalaan geometris, yaitu $1, \frac{1}{a}, \frac{1}{a^2}, \dots$ dan translasi oleh $0, n, 2n, \dots$. Transformasi wavelet yang diaplikasikan ke sinyal diskrit maka filter low-pass dan high-pass digunakan. Kemudian data akan terbagi ke dalam dua bagian yaitu bagian berfrekuensi rendah (aproksimasi) dan berfrekuensi tinggi (detail). Representasi data yang telah difilter dapat dianalisis lagi oleh wavelet dengan skala yang lebih kecil. Analisis dapat dilakukan pada salah satu bagian atau kedua bagian. Analisis yang dilakukan pada kedua bagian dikenal sebagai dekomposisi paket wavelet (Priyadarshani dkk., 2016).

KLASIFIKASI JENIS BURUNG BERDASARKAN SUARA MENGGUNAKAN MACHINE LEARNING

Support Vector Machine (SVM)

SVM sebagai *machine learning* memperkenalkan metode baru yaitu untuk mencari *hyperplane* terbaik dari dua *class* (Liu, 2011). *Hyperplane* terbaik adalah *hyperplane* yang terletak ditengah-tengah antara dua set objek dari dua kelas yang ditentukan dengan mengukur *maximum margin* (maksimum margin) dari *hyperplane* dan mencari titik maksimalnya. Nilai margin menentukan jarak antar kelas, sedangkan *support vector* adalah titik terdekat dengan *hyperplane* atau tepat berada diatas *hyperplane* pada masing-masing kelas. Proses mencari lokasi *hyperplane* terbaik merupakan inti dari proses pembelajaran SVM. SVM dalam memroses suara digunakan untuk pembagian segmen fonetis, pengenalan suara, dan identifikasi audio secara general (Fagerlund, 2007).

1. SVM Linier

SVM yang digunakan untuk menyelesaikan masalah linier yang disebut *Linear Separable Data* yaitu data yang dapat dipisahkan secara linear dari 2 *class* yaitu kelas -1 dan kelas +1 seperti pada gambar 2.1. Data yang masuk kelas -1 dirumuskan sebagai berikut:

$$(w \cdot x) + b = -1 \quad (2)$$

Sedangkan untuk data yang masuk kelas +1 dirumuskan sebagai data yang memenuhi persamaan berikut:

$$(w \cdot x) + b = +1 \quad (3)$$

Data dinotasikan sebagai $x_i \in \mathbb{R}^d$ sedangkan label masing-masing $y_i \in \{-1, +1\}$ untuk $i = 1, 2, 3, \dots, l$ dengan l adalah banyaknya data.

2. SVM Non-Linier

Terdapat kemungkinan bahwa titik pada dua kelas tidak dapat dipisah dengan sebuah *hyperplane* pada ruang yang sebenarnya. Untuk itu diperlukan ruang fitur yang lebih tinggi untuk mentransformasikan setiap data sehingga dapat dipisahkan secara linier oleh *hyperplane*. Untuk mengatasi masalah tersebut, diperkenalkan suatu kernel sehingga pencarian *hyperplane* menjadi cepat. Selain itu, masalah yang tidak linear separable (non-linier) dapat diatasi dengan fungsi kernel trick. Kernel trick merupakan fungsi yang memetakan fitur berdimensi rendah ke dimensi tinggi. Pada ruang vektor yang baru, *hyperplane* yang memisahkan kedua *class* dapat direkonstruksi (Nugroho, 2003).

Pemetaan dilakukan dengan tetap menjaga topologi suatu data yang berarti data yang berjarak dekat pada *input space* akan berjarak dekat pula pada *feature space*, begitu juga sebaliknya. Proses pembelajaran SVM untuk menemukan data sebagai titik *support vector* hanya bergantung pada *dot product* dari data yang sudah ditransformasikan ke ruang baru yang berdimensi tinggi yaitu:

$$\phi(\vec{x}_i) \cdot \phi(\vec{x}_j) \quad (4)$$

Umumnya transformasi ϕ tidak diketahui, sehingga perhitungan *dot product* sesuai teori Mercer dapat

digantikan fungsi kernel $K(\vec{x}_i, \vec{x}_j)$ yang mendefinisikan secara implisit transformasi ϕ . Inilah yang disebut dengan Kernel trick:

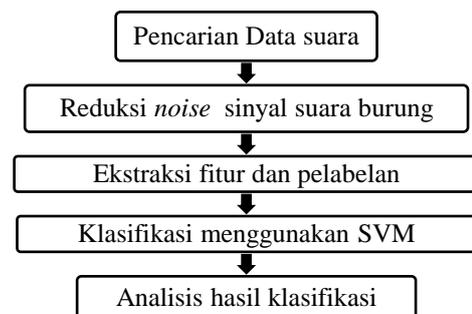
$$K(\vec{x}_i, \vec{x}_j) = \phi(\vec{x}_i) \cdot \phi(\vec{x}_j) \quad (5)$$

Untuk menentukan *support vector* pada SVM maka dibutuhkan fungsi kernel. Macam-macam fungsi kernel disajikan pada Tabel 1.

Tabel 1. Kernel-kernel pada SVM

Nama Kernel	Definisi Kernel
Linier	$K(x, y) = x \cdot y$
Polinomial of degree d	$K(x, y) = (x \cdot y)^d$
Polinomial of degree up to d	$K(x, y) = (x \cdot y + c)^d$
Gaussian RBF	$K(x, y) = \exp\left(\frac{-\ x-y\ ^2}{2\sigma^2}\right)$
Sigmoid (Tangen Hiperbolik)	$K(x, y) = \tanh(\sigma(x, y) + c)$
Invers Multi Kuadrat	$K(x, y) = \frac{1}{\sqrt{\ x - y\ ^2 + c^2}}$
Additive	$K(x, y) = \sum_{i=1}^n K_i(x_i, y_i)$

3. METODE



Gambar 2. Diagram Blok Proses Penelitian

Penelitian ini terdiri dari dua proses yaitu pra-pemrosesan dan klasifikasi. Proses pra-pemrosesan meliputi proses reduksi *noise* yang bertujuan untuk menghilangkan suara bising pada data suara. Proses ini menggunakan transformasi wavelet. Proses penelitian diilustrasikan pada Gambar 2.

1. Pencarian Data Suara

Data suara yang digunakan pada penelitian ini adalah *dataset Machine Learning for Signal Processing (MLSP) 2013 Bird Classification Dataset* yang tersedia di bank data daring Kaggle. *Dataset* ini merupakan data sampel yang dikumpulkan di Hutan Penelitian Eksperimental Jangka Panjang H. J. Andrews (HJA), di pegunungan Cascade di Oregon pada tahun 2009-2010. Rekaman suara yang dihasilkan pada *dataset* ini memiliki suara bising alam seperti suara hujan, angin, dan guntur yang mengakibatkan suara burung yang terekam tidak terdengar jelas (Lei & Huang, 2013).

2. Reduksi noise Sinyal Suara Burung

Proses reduksi noise dilakukan bertujuan untuk mendapatkan sinyal suara yang lebih jernih. Proses reduksi noise pada sinyal suara diawali dengan penentuan mother wavelet terlebih dahulu. Penelitian ini, menggunakan mother wavelet Daubechies 16. Selanjutnya dilakukan pembacaan sinyal suara yang hasil datanya akan diklasifikasikan. Tahap selanjutnya penentuan level untuk proses transformasi wavelet. Penentuan level terbaik pada dekomposisi wavelet dapat dilakukan dengan pendekatan komputasi dengan mempertimbangkan berapa banyak informasi tentang sinyal yang terkandung dalam setiap node, dengan syarat node tersebut tidak mengandung informasi yang mewakili noise. Pendekatan komputasi tersebut dapat dilakukan dengan menggunakan Entropi Shannon. Entropi Shannon memberikan ukuran standar gangguan pada suatu sistem. Koefisien wavelet akan melalui proses *Tresholding* yang dilakukan dengan melewati koefisien wavelet tersebut akan dilewatkan ke dalam suatu ambang batas yang telah ditentukan. Proses yang terakhir yaitu proses invers transformasi wavelet untuk mendapatkan sinyal suara yang *noise*-nya telah direduksi.

Keberhasilan proses reduksi *noise* pada sinyal suara diukur dengan menghitung Peak Signal to Noise Ratio (*PSNR*). *PSNR* melihat pada nilai puncak yang dapat dicapai sinyal dan rata-rata kuadrat antara referensi dan sinyal uji. Rumus *PSNR* sebagai berikut

$$PSNR = 20 \log_{10} \left(\frac{MAX_{sig}}{\sqrt{MSE}} \right) \quad (6)$$

di mana MAX_{sig} adalah nilai maksimum sinyal referensi dan MSE adalah Mean-Squared Error.

3. Ekstraksi fitur dan pelabelan

Pada tahap ini setiap data yang telah dibagi akan melalui proses ekstraksi fitur dengan menggunakan Algoritme Wavelet Daubechise 8 dengan level 1-8. Proses ini bertujuan untuk memperoleh fitur ciri dari setiap data. Sehingga dengan melakukan proses tersebut akan mempercepat dan meningkatkan akurasi pada proses klasifikasi. Kemudian setelah dilakukan ekstraksi fitur dilakukan pelabelan data. Pada penelitian ini data dilabeli dari jenis burung satu hingga tujuh. Label data suara burung disajikan pada Tabel 2.

Tabel 2. Pelabelan data suara

Jenis Burung	Label
Brown Creeper	1
Pacific Wren	2
Pacific-slope Flycatcher	3
Red-breasted Nuthatch	4
Dark-eyed Junco	5

4. Klasifikasi menggunakan algoritme SVM

Data yang sudah melalui tahap prapemroses, kemudian diklasifikasikan menggunakan algoritme SVM. *Output* hasil klasifikasi adalah besar akurasi, waktu pelatihan dan pengujian.

4. DATASET

MLSP *Dataset* merupakan *dataset* yang terdiri dari 645 data suara rekaman burung yang masing - masing rekaman suara memiliki durasi rekaman sepanjang 10 detik. Setiap data berekstensi WAV, dengan *sample rate* 16kHz. *Dataset* ini menyediakan rekaman suara yang berasal dari 19 jenis burung yang berbeda, dengan banyak data setiap jenis tidak homogen. Pada penelitian ini, dipilih sebanyak 5 jenis burung yang akan diklasifikasi. Pemilihan tersebut dengan mempertimbangkan jumlah data suara pada setiap jenis burung. Data suara telah diurutkan berdasarkan nama *file* rekaman suara yaitu, data ke 1-40 adalah rekaman jenis burung Brown Creeper, data ke 41-80 adalah rekaman jenis burung Pacific Wren, data ke 81-120 adalah rekaman jenis burung Pacific-slope Flycatcher, data ke 121-160 adalah rekaman jenis burung Red-breasted Nuthatch, dan data ke 161-200 adalah rekaman jenis burung Dark-eyed Junco.

5. PEMBAHASAN

Data suara burung yang mengandung noise alam yang terekam bersamaan dengan suara burung melalui proses reduksi noise dengan transformasi wavelet. Sinyal suara burung diakuisisi terlebih dahulu sebelum melalui proses transformasi wavelet. Kemudian pemilihan level yang dihasilkan oleh Entropi Shannon berbeda-beda. Hal ini disebabkan oleh kualitas suara burung masing-masing. Transformasi wavelet yang digunakan untuk mendekomposisi sinyal suara adalah dengan menggunakan paket dekomposisi wavelet. Sinyal suara tersebut terbagi ke dalam dua bagian yaitu aproksimasi dan detail yang selanjutnya melalui proses *tresholding*. Proses *tresholding* ini menggunakan jenis *tresholding* soft. Nilai *PSNR* pada semua sinyal suara menghasilkan nilai yang lebih tinggi dibandingkan sinyal suara sebelum reduksi noise. Nilai *PSNR* yang dihasilkan disajikan pada tabel 2.

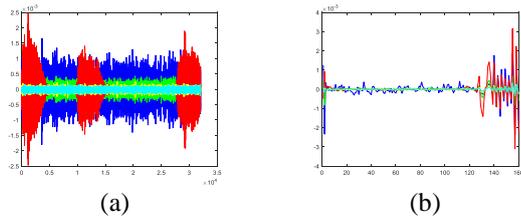
Tabel 3. *PSNR* sinyal suara sebelum dan sesudah reduksi

Jenis	<i>PSNR</i> sebelum Reduksi	<i>PSNR</i> setelah Reduksi
Brown Creeper	-22.8857	3.8967
Pacific Wren	-25.4405	1.3419
Pacific-slope Flycatcher	-18.9075	7.8749
Red-breasted Nuthatch	-22.4987	0.0242
Dark-eyed Junco	-22.5709	8.2653

Sinyal suara hasil reduksi melalui proses ekstraksi fitur untuk mendapatkan fitur khas masing-masing data suara. Proses ini dapat mempercepat proses klasifikasi dan meningkatkan akurasi. Proses ekstraksi pada level 4-8 menghasilkan data dengan banyak fitur yang beragam. Pemilihan fitur pada setiap level dilakukan dengan mengambil seluruh seluruh fitur pada level akhir kemudian akan diambil nilai maksimal, minimum dan rata-rata pada setiap level selanjutnya. Grafik Sinyal suara sebelum dan sesudah diekstraksi ditunjukkan pada Gambar 4. Data hasil ekstraksi akan diberikan label kelas pada setiap jenis.

KLASIFIKASI JENIS BURUNG BERDASARKAN SUARA MENGGUNAKAN MACHINE LEARNING

Kemudian data setiap jenis digabung dan disimpan dalam satu file berekstensi (.txt) untuk digunakan dalam proses klasifikasi.



Gambar 3. Full Feature (a) Hasil ekstraksi wavelet Db8 Level 8

Setelah melalui tahap ekstraksi fitur menggunakan wavelet, data berupa matriks akan melalui tahap klasifikasi menggunakan algoritma *Support Vector Machine* pada Weka. Proses klasifikasi terbagi ke dalam 2 proses yaitu pelatihan dan pengujian. Kinerja klasifikasi ditentukan dengan menghitung akurasi dan F-Measure menggunakan konfusi matrik.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100\% \quad (7)$$

Penghitungan akurasi dengan konfusi matrik dilakukan pada setiap kelas data. Nilai tersebut kemudian dihitung untuk mendapatkan akurasi pada keseluruhan data.

$$F - Measure = \frac{Precision \cdot Recall}{Precision + Recall} \quad (8)$$

dengan $precision = \frac{TP}{TP+FP}$ dan $Recall = \frac{TP}{TP+FN}$.

Hasil kinerja klasifikasi yang telah dilakukan pada data sinyal suara burung yang telah diekstraksi dengan wavelet menggunakan SVM dengan tipe kernel Heavy Tailed RBF dan pembagian rasio data 7:3 disajikan pada tabel-tabel berikut ini. Pada tabel nilai c merupakan nilai *complexity*.

Tabel 4. Hasil Klasifikasi menggunakan algoritme SVM dengan menggunakan epsilon = $1.00e - 09$

c	Akurasi (%)	Waktu pelatihan (s)	Waktu Pengujian (s)
1	29,00	1,89	3,01
10	51,00	1,82	2,58
100	72,00	2,34	2,11
1.000	75,00	3,12	1,80
10.000	77,00	3,28	1,99

Dari Tabel 6 didapatkan akurasi terbesar yang dihasilkan oleh percobaan klasifikasi dengan epsilon = $1.00e - 09$ dan c = 1.000 yaitu 77,00%, waktu pelatihan 3,28 detik dan waktu pengujian 1,99 detik.

Tabel 5. Hasil Klasifikasi menggunakan algoritme SVM dengan menggunakan epsilon = $1.00e - 06$

c	Akurasi (%)	Waktu pelatihan (s)	Waktu Pengujian (s)
1	28,67	1,79	2,81
10	52,00	1,73	2,37
100	69,33	1,70	2,20
1.000	62,67	1,64	2,26
10.000	69,67	1,69	2,25

Dari Tabel 5 didapatkan akurasi terbesar yang dihasilkan oleh percobaan klasifikasi dengan epsilon = $1.00e - 06$ dan c = 10.000 yaitu 69,67, waktu pelatihan 1,58 detik dan waktu pengujian 2,28 detik.

Tabel 6. Hasil Klasifikasi menggunakan algoritme SVM dengan menggunakan epsilon = $1.00e - 03$

c	Akurasi (%)	Waktu pelatihan (s)	Waktu Pengujian (s)
1	28,67	1,81	2,82
10	51,67	1,8	2,37
100	69,67	1,68	2,19
1.000	72,33	1,66	2,27
10.000	68,00	1,67	2,28

Dari Tabel 6 didapatkan akurasi terbesar yang dihasilkan oleh percobaan klasifikasi dengan epsilon = $1.00e - 03$ dan c = 1.000 yaitu 72,33%, waktu pelatihan 1,66 detik dan waktu pengujian 2,27 detik. Hasil akurasi dihasilkan dari penghitungan *confusion matrix* pada setiap kelas. Tabel 7, 8, dan 9 menyajikan *confusion matrix* untuk percobaan akurasi tertinggi dengan epsilon yang berbeda.

Tabel 7. *Confusion Matrix* hasil klasifikasi tertinggi dengan epsilon = $1.00e - 09$

Prediksi Kelas \	1	2	3	4	5
1	43	6	5	4	4
2	2	41	3	2	1
3	4	3	42	4	5
4	2	4	2	44	9
5	1	0	5	3	61

Tabel 8. *Confusion Matrix* hasil klasifikasi tertinggi dengan epsilon = $1.00e - 06$

Prediksi Kelas \	1	2	3	4	5
1	43	2	10	5	2
2	2	41	5	0	1
3	6	3	36	5	8
4	2	4	6	31	18
5	2	1	9	0	58

Tabel 9. *Confusion Matrix* hasil klasifikasi tertinggi dengan epsilon = $1.00e - 03$

Prediksi Kelas	1	2	3	4	5
1	43	3	10	5	1
2	2	40	6	0	1
3	4	6	36	6	6
4	2	4	4	45	5
5	0	0	6	9	55

Berdasarkan ketiga tabel *Confusion matrix* yang disajikan pmenunjukkan bahwa nilai akurasi yang dihasilkan oleh percobaan dengan epsilon = $1.00e - 09$ dan $c = 1.000$ menghasilkan nilai TP dan TN yang terbaik. Artinya percobaan tersebut mengklasifikasikan setiap kelas dengan banyak data yang lebih banyak dari setengah jumlah data yang diklasifikasi. Berikut Tabel 10 untuk mendukung hasil klasifikasi.

Tabel 10. Nilai Precision, Recall, dan F-Measure nilai akurasi tertinggi

epsilon	c	Akurasi (%)	Precision	Recall	F-Measure
1.00e-09	10.000	77,00	0,77	0,77	0,77
1.00e-06	10.000	69,67	0,71	0,69	0,69
1.00e-03	1.000	72,33	0,73	0,72	0,72

6. KESIMPULAN

Pada penelitian klasifikasi jenis burung berdasarkan suara menggunakan 5 jenis burung dengan melalui proses reduksi *noise* terlebih dahulu. Hasil sinyal suara yang telah direduksi *noise*-nya menghasilkan sinyal suara yang lebih jernih dengan PSNR sebesar 4,2890. Klasifikasi dengan menggunakan SVM Kernel Heavy Tailed RBF dan rasio 7:3 menghasilkan akurasi sebesar 77,00% dengan parameter epsilon = $1.00e - 09$ dan $c = 10.000$.

DAFTAR PUSTAKA

(2002). In H. S. Alikodra, *Pengelolaan Satwa Liar*. Bogor: Yayasan Penerbit Fakultas Kehutanan.
 Elias Sprengel, Jaggi, M., Kilcher, Y., & Hofmann, T. (2016). Audio based bird species identification using deep learning techniques. *CLEF*.
 Fagerlund, S. (2007). Bird Species Recognition Using Support Vector Machines. *EURASIP Journal on Advances in Signal Processing*.
 Gibbens, S. (2018, September 5). These 8 Bird Species Have Disappeared This Decade. Retrieved from National Geographic: <https://www.nationalgeographic.com/environment/2>

018/09/news-macaw-extinct-bird-species-deforestation/
 Graps, A. (2004). Introduction to the Discrete Wavelet Transform (DWT) DWT decomposition DWT in one dimension, 3, 1–8.
 Li, W., & Liu, Z. (2011). A Method of SVM with Normalization in Intrusion Detection. *Procedia Environmental Sciences* 11, 256-262.
 Merry, R. (2005). *Wavelet theory and applications*. Eindhoven.
 Nilsson, N. J. (2005). *Introduction To Machine Learning*. Department of Computer Science Stanford University.
 Nugroho, A. S., Witarto, A. B., & Hand, D. (2003). Support Vector Machine: Teori dan Aplikasinya dalam Bioinformatika. Retrieved from Ilmu Komputer: <http://ilmukomputer.com>
 Pourhomayoun, M., Dugan, P. J., Popescu, M., Risch, D., Lewis III, H. W., & Clark, C. W. (2013). Classification for Big Dataset of Bioacoustic Signals Based on Human Scoring System and Artificial Neural Network. *Computer Vision and Pattern Recognition*.
 Priyadarshani, N., Marsland, S., Castro, I., & Punchihewa, A. (2016). Birdsong denoising using wavelets. *PLoS ONE*, 11(1), 1–26. <https://doi.org/10.1371/journal.pone.0146790>
 Raghuram, M. A., Chavan, N. R., Belur, R., & Koolagudi, S. G. (2016). Bird classification based on their sound patterns. *Springer*, 791-804.
 Singh, M., & Singh, M. (2014). Audio Noise Reduction Using Wavelet Types With Thresholding Techniques. *International journal of computer and organisational trends*, 6(1), 86–89.
 Tóth, B. P., & Czeba, B. (2016). Convolutional Neural Networks for Large-Scale Bird.
 Turesson, H. K., Ribeiro, S., Pereira, D. R., Papa, J. P., & C. de Albuquerque, V. H. (2016). Machine Learning Algorithms for Automatic Classification of Marmoset Vocalizations.
 Upadhyay, R. K., Rai, V., & Iyengar, S. (2001). Species Extinction Problem: Genetic vs Ecological Factors. *Applied Mathematical Modelling* 25, 937-951.
 Valletta, J. J., Torney, C., Kings, M., Thornton, A., & Madden, J. (2017). Applications of Machine Learning in Animal Behaviour Studies. *Animal Behaviour* 124, 203-220.
 Zhang, Y., Cao, H., Jiang, H., & Li, B. (2016). Memory Efficient High Speed VLSI Implementation of Multi Level Discrete Wavelet Transform. *Elsevier*, 297-306.