



Model Pengenalan Suara Teks Bebas Menggunakan Algoritma Support Vector Machine

Muhammad Bobbi Kurniawan Nasution, Kusmanto, Sudi Suryadi, Ronal Watrianthos*

Fakultas Teknik, Teknik Informatika, Universitas Al Washliyah Labuhanbatu, Rantauprapat, Indonesia

Email: ¹bobbi.kurniawan@univalabuhanbatu.ac.id, ²kusmanto@univalabuhanbatu.ac.id, ³soesoe@univalabuhanbatu.ac.id,

^{4,*}ronalw@univalabuhanbatu.ac.id

Email Penulis Korespondensi: ronalw@univalabuhanbatu.ac.id

Abstrak—Autentikasi suara bisa dilakukan karena ada perbedaan fisik organ produksi suara dari setiap orang. Pola suara yang diucapkan pengguna dapat digunakan sebagai perintah suara sesuai keinginan. Beberapa ciri seperti aksen, intonasi, dan cara pengucapan menghasilkan pola berbeda. Untuk verifikasi pengenalan, data suara dibagi dua kelompok yaitu suara dengan teks yang sudah ditentukan dan suara dengan teks bebas. Suara yang dihasilkan dari pengucapan kata tertentu bisa diubah dari analog ke bentuk digital. Proses perubahan ini akan menghasilkan sebuah representasi dalam bentuk vektor. Salah satu teknik dalam klasifikasi pengenalan suara adalah Support Vector Machine (SVM). Penelitian ini bertujuan mengembangkan algoritma SVM untuk membuat model pengenalan pola suara berbasis teks bebas. Proses klasifikasi pola suara menggunakan tiga kernel untuk data set sehingga hasil perbandingan akan lebih akurat. Akurasi tertinggi pada kernel *linear* terdapat pada perulangan ke-4 pada *fold* ketiga dengan tingkat akurasi sebesar 94,40%. Sedangkan pada kernel *polynomial* akurasi tertinggi pada perulangan ke-6 *fold* kedua dengan akurasi sebesar 96,80%. Tingkat akurasi tertinggi terdapat pada kernel RBF pada perulangan ke-8 *fold* ketiga dengan akurasi mencapai 98,20%. Hasil pengujian ini membuktikan kernel RBF memiliki tingkat akurasi paling baik dalam pengenalan suara berbasis teks bebas.

Kata Kunci: Suara, Autentikasi, RBF, Support Vector Machine, SVM

Abstract—Voice authentication can be done because there are physical differences in the voice production organs of each person. The user's spoken sound pattern can be used as a voice command as desired. Some features such as accents, intonation, and the way pronunciation produce different patterns. For identification verification, voice data is divided into two groups: voice with defined text and voice with free text. Sounds resulting from the pronunciation of a particular word can be changed from analog to digital form. This change process will result in representation in vector form. One technique in voice recognition classification is the Support Vector Machine (SVM). The study aims to develop SVM algorithms to create free text-based speech patterns, recognition models. The sound pattern classification process uses three kernels for the data set so that the comparison results will be more accurate. The highest accuracy in the linear kernel is found in the 4th loop in the third fold with an accuracy rate of 94.40%. While in the polynomial kernel the highest accuracy at the 6th iteration of the second fold with an accuracy of 96.80%. The highest accuracy rate is found in the RBF kernel on the 8th loop of the third fold with 98.20% accuracy. These test results prove that the RBF kernel has the best level of accuracy in free text-based speech recognition.

Keywords: Voice, Autentication, RBF, Support Vector Machine, SVM

1. PENDAHULUAN

Sistem autentikasi pada manusia saat ini berkembang dari sebelumnya hanya pengenalan sidik jari, wajah, iris mata, kepada pengenalan suara (*voice recognition*) [1]. Autentikasi suara bisa dilakukan karena ada perbedaan fisik organ produksi suara dari setiap orang. Pola suara yang diucapkan pengguna dapat digunakan sebagai perintah suara sesuai keinginan[2]. Karakter lainnya seperti aksen, intonasi, dan cara pengucapan juga sebagai faktor pembeda. Untuk verifikasi pengenalan, data suara bisa dibagi dua kelompok yaitu suara dengan teks yang sudah ditentukan (*text-dependent*) dan suara dengan teks bebas (*text-independent*)[3]. Dalam *text-dependent* sistem, pengenalan katanya tetap dan tidak berubah[4]. Sedangkan dalam *text-independent*, tidak pembatasan dalam penggunaan kata[5].

Suara yang dihasilkan berasal dari pengucapan kata-kata tertentu akan diubah dari bentuk analog ke dalam bentuk digital. Proses perubahan ini akan menghasilkan sebuah representasi dalam bentuk vektor. Vektor suara akan diekstraksi ke dalam vektor ciri tanpa mengurangi karakteristik suara tersebut. Ekstraksi ciri bertujuan untuk menajamkan perbedaan pola. Proses ini akan memudahkan dalam memisahkan kategori-kategori kelas ketika dilakukan klasifikasi[6][7]. Salah satu metode teknik ekstraksi adalah *mel-frequency cepstrum coefficients* (MFCC) digunakan karena mendekati sistem pendengaran manusia[8].

Permasalahan dari ekstraksi ciri adalah proses pemodelan yang membutuhkan waktu lama terutama pada data suara teks bebas yang memiliki ukuran lebih besar sehingga perlu direduksi. Teknik reduksi bisa dilakukan dengan metode *long term statistics based systems*, namun dapat menghilangkan banyak informasi penting karena data tersebut hanya diambil nilai rata-ratanya[9]. Teknik lainnya adalah *vector quantization* yang mampu mereduksi data tanpa mengurangi kualitasnya[10]. Sedangkan menurut penelitian lain, data hasil ekstraksi MFCC dapat direduksi dengan tetap menjaga kualitasnya[11].

Teknik klasifikasi pengenalan suara menggunakan algoritma Support Vector Machine (SVM) sudah banyak diteliti. Salah satu penelitian mengungkapkan SVM mampu menghasilkan pola suara dengan baik menggunakan metode pembagian dua wilayah secara linear. Namun memiliki masalah dengan waktu pemodelan yang lama ketika menggunakan data yang besar[12]. Penelitian lain mengungkapkan bahwa SVM memiliki



masalah dalam memilih kernel yang tepat untuk dataset[13]. Namun metode SVM dapat diterapkan[14] dalam penentuan jenis kelamin melalui pengenalan suara dengan menggunakan algoritma MFCC (Mel-Frequency Cepstral Coefficient) dengan tingkat akurasi sebesar 90,90% untuk laki-laki dan 81,81% untuk perempuan.

Penelitian ini bertujuan mengembangkan algoritma SVM untuk membuat model pengenalan pola suara berbasis teks bebas. Proses klasifikasi pola suara menggunakan tiga kernel untuk data set sehingga hasil perbandingan akan lebih akurat. Hasil yang diharapkan adalah model terbaik dari kernel SVM untuk mendapatkan akurasi tertinggi.

2. METODOLOGI PENELITIAN

Seperti yang ditunjukkan pada Gambar 1, tahapan penelitian ini terdiri dari enam tahap yaitu pengumpulan data, pra-proses data, ekstrasi ciri, vektor kuantisasi, pembagian data training dan data testing, dan pengujian dengan metode SVM.



Gambar 1. Tahapan Penelitian

Berdasarkan Gambar 1, dapat dijelaskan tahapan-tahapan penelitian sebagai berikut:

1. Pengumpulan Data.

Tahapan ini akan mengumpulkan data hasil rekaman pembicara secara acak yang direkam menggunakan *headphone* berisi kata berbahasa Indonesia sebanyak 500 kata.

2. Pra-proses Data.

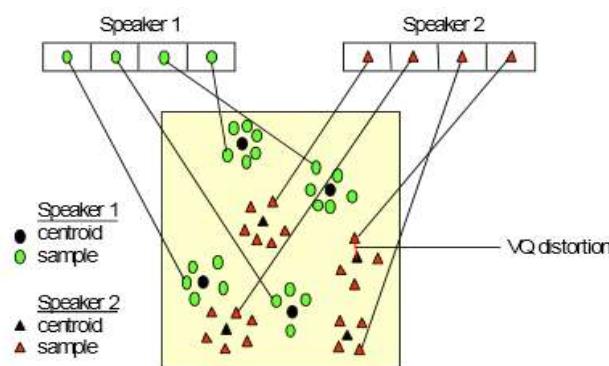
Pada tahap ini terjadi proses normalisasi data dengan merubah data pada rentang -1 dengan 1 untuk mengurangi selisih amplitudo pada perbedaan suara rendah dan tinggi. Selanjutnya dilakukan *silent removal* dengan menghapus suara diam agar tidak terjadi data yang kosong.

3. Ekstrasi Ciri

Setelah normalisasi, akan dilakukan ekstrasi ciri dengan menggunakan Mel-Frequency Cepstral Coefficient (MFCC). MFCC merupakan teknik ekstrasi ciri yang digunakan dalam pemrosesan sinyal suara. Ekstrasi ciri dalam proses ini berupa perubahan data suara menjadi data gambar berbentuk spektrum gelombang[15]. Parameter-parameter tertentu akan digunakan pada tahap ini.

4. Kuantisasi Vektor

Setelah didapatkan data hasil ekstrasi ciri, kemudian data direduksi untuk mengurangi ukurannya dengan tujuan mempercepat waktu pemodelan. Tahap ini menggunakan kuantisasi vektor yang merupakan teknik kompresi data pada pengenalan citra atau suara. Kuantisasi vektor merupakan metode pemrosesan sinyal yang digunakan untuk pemodelan fungsi kerapatan peluang dengan alokasi vektor mode. Dalam kuantisasi vektor, titik-titik informasi diwakili oleh *centroid*[16].



Gambar 1. Ilustrasi Kuantisasi Vektor[17]

5. Pembagian Data Training dan Data Testing

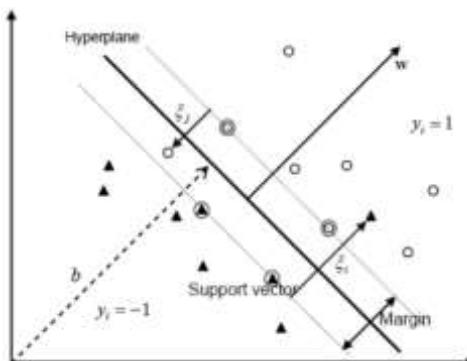
Tahap ini menggunakan metode *k-fold cross validation* untuk menguji model berdasarkan sampel pengujian yang diambil. Metode ini akan menghasilkan data acak yang berpengaruh kepada akurasi. Metode ini bekerja



dengan cara memecah data menjadi k bagian set data dengan ukuran yang sama. Penggunaan k-fold cross validation untuk menghilangkan bias pada data[18].

6. Pemodelan dengan klasifikasi Support Vector Machine (SVM)

Pada tahap ini akan dilakukan pemodelan dengan parameter dan nilai yang telah ditentukan. Pemodelan SVM dengan tujuan mencari data untuk menghasilkan akurasi yang terbaik dari kombinasi nilai parameter yang diujikan pada *kernel linear, polynomial, dan Radial Basis Function (RBF)*. Metode klasifikasi SVM merupakan metode klasifikasi yang membagi ruang vektor menjadi dua bagian yaitu kelas positif dan kelas negatif oleh *hyperplane*[19]. SVM merupakan *machine learning* klasifikasi data menjadi dua kelompok menggunakan fungsi-fungsi linear dalam sebuah ruang fitur berdimensi tinggi. Klasifikasi SVM dilakukan dengan cara menemukan *hyperplane* terbaik untuk memperoleh margin maksimal[20]. Gambar 2 menunjukkan ilustrasi SVM linear data terpisah dimana dua kelas dipisahkan menggunakan sepasang bidang batas yang sejajar. Bidang batas pertama akan membatasi kelas pertama ($y_i=1$) dan bidang batas kedua membatasi kelas kedua ($y_i=-1$)[21].



Gambar 2. SVM Linear Data Terpisah

3. HASIL DAN PEMBAHASAN

Penggunaan data suara penelitian ini menggunakan hasil rekaman dari 5 suara dengan rentang umur 30-40 tahun seperti yang disajikan dalam tabel di bawah ini. Data suara direkam menggunakan headphone pada komputer dengan menggunakan aplikasi audiocity.

Tabel 1. Data Suara

Nama File	Nama Data	Jenis Kelamin
Suara1.wav	Bobbi	Laki-Laki
Suara2.wav	Kusmanto	Laki-Laki
Suara3.wav	Fitri	Perempuan
Suara4.wav	Sabrina	Perempuan
Suara5.wav	Anto	Laki-Laki

Setelah dilakukan pengumpulan data, dilakukan praproses yang terdiri dari *silence removal* dan normalisasi. Tahap *silence removal* adalah tahap untuk menghilangkan suara diam/kosong. Sedangkan tahap normalisasi untuk menghasilkan data dengan rentang maksimum 1 dan minimum -1. Rentang nilai ini diperoleh dari pembagian setiap elemen data dengan nilai maksimum dari suatu data. Persamaan pada bidang ini dihitung menggunakan perkalian antara vektor dengan vektor bobot seperti pada persamaan 1.

$$\begin{aligned} w \cdot x_i + b &\geq 1 && \text{untuk kelas 1 } y_i = 1 \\ w \cdot x_i + b &\leq -1 && \text{untuk kelas 2 } y_i = -1 \end{aligned} \quad (1)$$

dengan:

xi: data set

Hasil normalisasi akan terlihat durasi rekam setiap data berbeda. Perbedaan data ini akan berpengaruh kepada dimensi data. Proses ekstrasi ciri kemudian dilakukan dengan menggunakan MFCC dengan parameter *time frame* 40, *sampling rate* 11000Hz, *overlap* 0,5 dan jumlah koefesien 13 seperti yang ditunjukkan pada Tabel 2.

Tabel 2. Perbandingan Data Setelah Normalisasi dan Ekstrasi Ciri

Data Suara	Hasil Normalisasi (baris x kolom)	Hasil Eskstrasi Ciri (baris x kolom)
1	16.769.486 x 1	13 x 76224
2	14.032.424 x 1	13 x 63783
3	14.959.683 x 1	13 x 67998



Data Suara	Hasil Normalisasi (baris x kolom)	Hasil Esktrasi Ciri (baris x kolom)
4	14.431.084 x 1	13 x 65595
5	14.569.394 x 1	13 x 66224

Dalam Tabel 1 terlihat dimensi masing-masing data sangat besar dan akan menghambat proses *training* sehingga diperlukan metode *vector quantization* untuk mengurangi dimensi data. Melalui *vector quantization*, dimensi data akan dikurangi menjadi beberapa *cluster*. Dalam penelitian ini, hasil ekstrasi ciri menggunakan MFCC dengan dimensi data 13 x >1000 akan dikurangi menjadi 13 x 100 seperti yang ditunjukkan pada Tabel 3.

Tabel 3. Perbandingan Data Setelah *Vector Quantization*

Data Suara	Hasil Esktrasi Ciri (baris x kolom)	Hasil Esktrasi Ciri (baris x kolom)
1	13 x 76224	13 x 100
2	13 x 63783	13 x 100
3	13 x 67998	13 x 100
4	13 x 65595	13 x 100
5	13 x 66224	13 x 100

Dari Tabel 3 terlihat dimensi data suara telah direduksi ukuran datanya menjadi 13 x 100. Nilai 13 adalah jumlah koefisien/penciri yang digunakan untuk pemodelan, sedangkan 100 merupakan jumlah *codeword* yang dapat disesuaikan dengan kebutuhan penelitian. *Codeword* merupakan titik pusat (*centroid*) dari kluster hasil reduksi dengan metode *vector quantization*. Nilai *centroid* ini yang akan digunakan untuk pemodelan SVM.

Setelah centroid didapatkan, langkah selanjutnya adalah membagi data training dengan data uji. Pembagian ini didasarkan pada kolom data pada Tabel 3 hasil *vector quantization* dengan total data 13 x 500 yang artinya nilai koefisien ditunjukkan pada nilai 13 dan total data pada nilai 500. Pembagian data training dan data uji dilakukan dengan perbandingan 75% data training dan 25% data uji sehingga didapatkan data training sebesar 375 dan data uji sebesar 125 seperti yang ditunjukkan pada Tabel 4.

Tabel 4. Perbandingan Data Training dan Data Uji

Data Training	Data Uji
13 x 75	13 x 25
13 x 75	13 x 25
13 x 75	13 x 25
13 x 75	13 x 25
13 x 75	13 x 25
Total: 13 x 375 data	Total: 13 x 125 data

Setelah data *training* dan data *uji* didapatkan, kemudian dilakukan pemilihan data secara acak menggunakan teknik *k-fold cross validation*. Hasilnya dari total 100 data suara akan didapatkan 25 *subset* data (S) hasil pengacakan dengan nilai *k*=4 seperti yang ditunjukkan pada tabel 4.

Tabel 4. Pembagian Data Training dan Data Uji Menggunakan K-Fold Cross Validation

Fold	Data Training	Data Uji
F1	S1, S2, S3	S4
F2	S1, S2, S4	S3
F3	S1, S3, S4	S2
F4	S2, S3, S4	S1

Dalam Tabel.4 terdapat empat fold pengujian yaitu F1, F2, F3, dan F4 menggunakan berbagai macam kombinasi *subset* untuk menghasilkan akurasi tertinggi. Kemudian dilakukan perulangan sebanyak 20 kali untuk menghasilkan akurasi tertinggi. Dalam perulangan, terdapat 20 kombinasi data yang akan diuji pada pemodelan dengan parameter yang telah ditentukan. Kombinasi data akan diuji dengan pemodelan Support Vector Machine (SVM) dengan tujuan mencari data untuk menghasilkan akurasi yang terbaik dari kombinasi nilai parameter yang diujikan pada *kernel linear, polynomial, dan Radial Basis Function (RBF)*. Penentuan nilai parameter SVM pada setiap *kernel* dapat dilihat pada Tabel.5.

Tabel 5. Nilai Parameter SVM Pada Setiap Kernel

Kernel	C	d	γ
	10		
	20		
Linear	30	-	-
	40		
	50		



<i>Kernel</i>	<i>C</i>	<i>d</i>	γ
Polynomial	10	2	
	20	4	
	30	6	-
	40	8	
	50	10	
RBF	10		10
	20	-	20
	30		30
	40		40
	50		50

Secara detail hasil pengujian yang disajikan lima perulangan pertama (P1-P5) pada pengujian model SVM dengan kernel *linear* pada parameter yang ditentukan bisa dilihat pada Tabel 6.

Tabel 6. Pengujian Model SVM Pada Kernel Linear

		<i>C</i>					Maksimum
		10	20	30	40	50	
Perulangan Ke-1	F1	80.00	81.50	75.00	76.00	85.70	85.70
	F2	77.60	78.70	75.20	68.80	68.00	78.70
	F3	77.50	77.50	68.30	67.30	65.20	77.50
	F4	86.70	67.20	84.50	79.10	79.00	86.70
Perulangan Ke-2	F1	70.00	76.50	75.90	77.60	66.00	77.60
	F2	72.30	79.00	86.40	69.30	74.20	86.40
	F3	71.20	84.00	75.00	62.20	69.20	84.00
	F4	76.30	74.30	92.00	79.40	65.10	92.00
Perulangan Ke-3	F1	80.00	81.60	75.00	66.00	76.00	81.60
	F2	78.60	77.10	79.20	78.80	80.00	80.00
	F3	77.90	79.50	87.20	69.80	84.80	84.80
	F4	84.80	77.20	84.10	82.10	75.10	84.80
Perulangan Ke-4	F1	85.60	71.60	79.00	76.00	78.00	85.60
	F2	79.60	77.90	89.00	88.80	80.00	89.00
	F3	79.80	78.50	87.10	67.00	94.40	94.40
	F4	74.80	79.20	64.80	82.80	89.60	89.60
Perulangan Ke-5	F1	84.80	79.60	69.00	66.00	78.00	84.80
	F2	79.60	87.90	79.00	78.90	88.00	88.00
	F3	79.50	76.80	86.10	67.90	64.20	76.80
	F4	78.80	77.90	69.40	88.00	79.90	88.00

Sedangkan pada pengujian pemodelan SVM dengan kernel polynomial didapatkan hasil seperti yang ditunjukkan pada Tabel.7 dengan sampel hanya sampai perulangan ke dua.

Tabel 7. Pengujian Model SVM Pada Kernel Polynomial

		<i>d</i>				<i>d</i>				<i>d</i>				<i>d</i>				Maks				
		2	4	6	8	10	2	4	6	8	10	2	4	6	8	10						
Peru- langan Ke -1	10	90.40	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	92.80
	20	90.40	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	92.80
	30	90.40	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	92.80
	40	90.40	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	92.80
	50	90.40	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	92.80
Peru- langan Ke -2	10	89.60	83.20	72.00	56.80	40.00	92.00	85.60	80.80	59.20	35.20	92.80	78.40	72.80	60.80	36.00	90.40	85.60	74.40	63.20	48.00	92.80
	20	89.60	83.20	72.00	56.80	40.00	92.00	85.60	80.80	59.20	35.20	92.80	78.40	72.80	60.80	36.00	90.40	85.60	74.40	63.20	48.00	92.80
	30	89.60	83.20	72.00	56.80	40.00	92.00	85.60	80.80	59.20	35.20	92.80	78.40	72.80	60.80	36.00	90.40	85.60	74.40	63.20	48.00	92.80
	40	89.60	83.20	72.00	56.80	40.00	92.00	85.60	80.80	59.20	35.20	92.80	78.40	72.80	60.80	36.00	90.40	85.60	74.40	63.20	48.00	92.80
	50	89.60	83.20	72.00	56.80	40.00	92.00	85.60	80.80	59.20	35.20	92.80	78.40	72.80	60.80	36.00	90.40	85.60	74.40	63.20	48.00	92.80

Berikutnya pengujian pemodelan SVM dengan kernel RBF didapatkan hasil seperti yang ditunjukkan pada Tabel.8 dengan sampel hanya sampai perulangan ke dua.

Tabel 8. Pengujian Model SVM Pada Kernel RBF

		<i>γ</i>					<i>γ</i>					<i>γ</i>					<i>γ</i>					Maks
		10	20	30	40	50	10	20	30	40	50	10	20	30	40	50	10	20	30	40	50	
Peru- langan Ke -1	10	92.00	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	94.40
	20	92.80	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	95.20
	30	92.80	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	94.40
	40	92.00	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	95.20
	50	92.00	84.80	78.40	68.00	53.60	91.20	81.60	71.20	60.80	33.60	92.80	83.20	76.80	64.80	51.20	88.80	86.40	81.60	65.60	32.00	95.20



	10	20	30	γ					Maks																		
				40	50	10	20	30	40	50	10	20	30	40	50	10	20	30	40	50	10	20	30	40	50		
Perulangan	10	91.20	88.00	84.80	82.40	82.40	79.20	88.00	84.00	80.80	80.80	80.00	90.40	88.00	80.00	78.40	80.80	92.80	90.40	80.00	78.40	92.80	90.40	80.00	78.40	92.80	
Ke -2	20	92.80	88.80	85.60	85.60	84.80	81.60	90.40	88.00	81.60	80.80	80.00	90.40	90.40	85.60	80.80	78.40	92.80	92.80	88.80	80.80	92.80	92.80	88.80	87.20	92.80	
	30	92.00	89.60	86.40	86.40	84.80	85.60	90.40	86.40	83.20	81.60	80.80	92.80	91.20	87.20	84.00	80.00	92.80	92.80	88.80	87.20	92.80	92.80	88.80	87.20	94.40	94.40
	40	91.20	89.60	88.00	88.00	85.60	84.80	90.40	86.40	84.00	81.60	80.80	92.80	89.60	87.20	84.80	80.00	94.40	91.20	89.60	87.20	94.40	94.40	88.80	87.20	94.40	
	50	91.20	89.60	87.20	87.20	85.60	84.80	92.00	86.40	84.80	81.60	80.80	92.80	89.60	88.00	86.40	84.00	94.40	90.40	91.20	88.80	94.40	94.40	88.80	87.20	94.40	

Hasil pengujian model SVM menggunakan tiga kernel ini secara lengkap sesuai parameter yang ditentukan berdasarkan akurasi tertinggi dapat dilihat pada Tabel 9.

Tabel 9. Perbandingan Akurasi Pemodelan SVM Pada Tiga Kernel

Perulangan ke-	C	Linear			Polynomial			RBF			
		Akurasi %	Fold ke-	C	d	Akurasi %	Fold ke-	C	γ	Akurasi %	Fold ke-
P1	10	86.40	F4	10	2	91.20	F3	10	10	95.20	F4
P2	10	92.00	F4	10	2	93.80	F3	40	10	94.40	F4
P3	40	84.80	F3	10	2	94.20	F4	10	10	96.80	F3
P4	10	94.40	F3	10	2	90.20	F2	20	10	96.00	F2
P5	10	88.00	F2	10	2	95.80	F2	50	10	96.80	F1
P6	10	92.80	F2	10	2	96.80	F2	20	10	96.00	F2
P7	20	90.40	F4	10	2	89.90	F4	20	10	96.00	F4
P8	10	89.60	F1	10	2	94.40	F3	40	10	98.20	F3
P9	10	88.00	F1	10	2	91.30	F1	30	10	97.60	F1
P10	10	87.20	F4	10	2	93.90	F4	40	10	92.70	F2
P11	10	91.20	F2	10	2	90.00	F3	20	10	96.00	F1
P12	10	94.40	F1	10	2	90.40	F4	40	10	95.20	F2
P13	10	87.20	F2	10	2	81.20	F4	30	10	96.00	F2
P14	10	90.40	F4	10	2	82.00	F4	20	10	94.40	F3
P15	10	94.40	F4	10	2	91.20	F3	96	10	96.00	F2
P16	10	90.20	F3	10	2	92.0	F3	10	10	95.20	F2
P17	50	87.20	F4	10	2	88.80	F4	30	10	96.80	F1
P18	20	81.40	F4	10	2	89.80	F4	10	10	94.40	F1
P19	20	88.20	F1	10	2	82.00	F1	30	10	95.20	F3
P20	10	82.80	F4	10	2	92.80	F1	30	10	95.20	F4

Hasil perbandingan dari tiga kernel didapatkan akurasi pada kernel RBF sebesar 98.20%, diikuti oleh kernel polynomial 96.80% dan kernel linear 94.40%. Berdasarkan hasil ini akurasi tertinggi dengan data terbaik terdapat pada kernel RBF sebesar 98.40% dengan data pada perulangan ke-8 fold ketiga.

4. KESIMPULAN

Penelitian ini melakukan pengujian dengan metode Support Vector Machine (SVM) dengan tujuan mencari data untuk menghasilkan akurasi yang terbaik dari kombinasi nilai parameter yang diujikan pada kernel linear, polynomial, dan Radial Basis Function (RBF). Akurasi tertinggi pada kernel linear terdapat pada perulangan ke-4 pada fold ketiga dengan tingkat akurasi sebesar 94,40%. Sedangkan pada kernel polynomial akurasi tertinggi pada perulangan ke-6 fold kedua dengan akurasi sebesar 96,80%. Tingkat akurasi tertinggi terdapat pada kernel RBF pada perulangan ke-8 fold ketiga dengan akurasi mencapai 98,20%. Hasil pengujian ini membuktikan kernel RBF memiliki tingkat akurasi tertinggi dalam pengenalan suara berbasis teks bebas dengan metode Support Vector Machine.

UCAPAN TERIMA KASIH

Terima kasih kepada Direktorat Riset dan Pengabdian kepada Masyarakat (DRPM) Kementerian Riset, Teknologi, dan Pendidikan Tinggi atas dibiayainya penelitian ini pada hibah Penelitian Dosen Pemula Tahun 2019-2020.

REFERENCES

- [1] I. Agustina, Fauziyah, and A. Gunaryati, "Biometrik Pola Suara Dengan Jaringan Saraf Tiruan," *J. Tek. Inform.*, vol. 9, no. 2, pp. 140–147, 2016.
- [2] R. Umar, I. Riadi, and A. Hanif, "Analisis Bentuk Pola Suara Menggunakan Ekstraksi Ciri Mel-Frequency Cepstral Coefficients (MFCC)," *CogITO Smart J.*, vol. 4, no. 2, p. 294, 2019, doi: 10.31154/cogito.v4i2.130.294-304.
- [3] T. Kinnunen and H. Li, "An Overview of Text-Independent Speaker Recognition: from Features to Supervectors," *Speech Commun.*, vol. 52, no. 1, 2009.
- [4] M. Hebert, "Text-dependent speaker recognition," in *In Springer handbook of speech processing*, 2009, pp. 743–762.



- [5] A. Azene, "Text-independent speaker identification for the amharic language," 2015.
- [6] S. Gustina, A. Fadlil, and R. Umar, "Sistem Identifikasi Jamur Menggunakan Metode Ekstraksi Ciri Statistik Orde 1 dan Klasifikasi Jarak," *Techno.COM*, vol. 16, no. 378–386, 2017.
- [7] M. Nasution, D. Irmayani, R. Watrianthos, S. Suryadi, and I. R. Munthe, "Comparative Analysis Of Data Mining Using The Rought Set Method With K-Means Method," *Int. J. Sci. Technol. Res.*, vol. 8, no. 05, pp. 38–40, 2019, [Online]. Available: <http://www.ijstr.org/final-print/may2019/Comparative-Analysis-Of-Data-Mining-Using-The-Rought-Set-Method-With-K-means-Method.pdf>.
- [8] E. Riyanto and Sutejo, "Perbandingan Metode Ekstraksi Ciri Suara MFCC, ZCPA, dan LPC, HIMSAYATECH," *J. Teknol. Inf.*, vol. 10, no. 1, 2014.
- [9] Muhammad Habib ur Rehman, C. S. Liew, A. Abbas, P. P. Jayaraman, T. Y. Wah, and S. U. Khan, "Big Data Reduction Methods: A Survey," *Data Sci. Eng.*, vol. 1, no. 4, pp. 265–284, 2016, doi: 10.1007/s41019-016-0022-0.
- [10] K. HB and S. TK, "Speech Data Compression Using Vector uantization," *WASET Int. J. Comput. Inf. Sci. Eng.*, vol. 2, no. 4, pp. 251–254, 2008.
- [11] Nijhawan G and P. P, "Isolated Speech Recognition using MFCC and DTW," *Int. J. Adv. Res. Electr. Electron. Instrum. Eng.*, vol. 2, no. 8, pp. 4085–4092, 2013.
- [12] N. Smith and M. Gales, "Speech Recognition using SVMs," in *Advances in Neural Information Processing Systems 14*, 2001.
- [13] M. DBA, B. SZ, and E. N, "Evaluation of SVM Kernels and Conventional Machine Learning Algorithms for Speaker Identification," *Int. J. Hybrid Inf. Technol.*, vol. 3, no. 3, pp. 23–34, 2010.
- [14] R. B. Handoko and S. Suyanto, "Klasifikasi Gender Berdasarkan Suara Menggunakan Support Vector Machine," *Indones. J. Comput.*, vol. 4, no. 1, p. 9, Mar. 2019, doi: 10.21108/INDOJC.2019.4.1.244.
- [15] T. Chamidy, "Metode Mel Frequency Cepstral Coefficients (MFCC) Pada klasifikasi Hidden Markov Model (HMM) Untuk Kata Arabic pada Penutur Indonesia," *MATICS*, vol. 8, no. 1, pp. 36–39, 2016.
- [16] D. Astuti, "Aplikasi Identifikasi Suara Hewan Menggunakan Metode Mel-Frequency Cepstral Coefficients (MFCC)," *J. Informatics, Inf. Syst. Softw. Eng. Appl.*, vol. 1, no. 2, pp. 26–34, May 2019, doi: 10.20895/inista.v1i2.50.
- [17] R. I. A. Casil, E. D. Dimaunahan, M. E. C. Manamparan, B. G. Nia, and A. A. B. Jr, "A DSP Based Vector Quantized Mel Frequency Cepstrum Coefficients for Speech Recognition," *Inst. Electron. Eng. Philipp. J.*, vol. 3, no. 1, pp. 1–5, 2014.
- [18] F. Tempola, M. Muhammad, and Amal Khairan, "PERBANDINGAN KLASIFIKASI ANTARA KNN DAN NAIVE BAYES PADA PENENTUAN STATUS GUNUNG BERAPI DENGAN K-FOLD CROSS VALIDATION," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 5, 2018.
- [19] N. Indriani, E. Rainarli, and K. E. Dewi, "Peringkasan dan Support Vector Machine pada Klasifikasi Dokumen," *J. INFOTEL*, vol. 9, no. 4, 2017, doi: <https://doi.org/10.20895/infotel.v9i4>.
- [20] P. Bojarczak and W. Nowakowski, "Squat detection in railway rails using Gabor filter bank, SVM classifier and Genetic Algorithms," in *Proceedings of 2017 15th International Conference on ITS Telecommunications, ITST 2017*, 2017, pp. 1–7, doi: 10.1109/ITST.2017.7972229.
- [21] S. jin Wang, A. Mathew, Y. Chen, L. feng Xi, L. Ma, and J. Lee, "Empirical analysis of support vector machine ensemble classifiers," *Expert Syst. Appl.*, vol. 36, no. 3 PART 2, pp. 6466–6476, 2009, doi: 10.1016/j.eswa.2008.07.041.