

SIMULASI DAN ANALISIS KLASIFIKASI *GENRE* MUSIK BERBASIS *SUPPORT VECTOR MACHINE*
SIMULATION AND ANALYSIS OF SUPPORT VECTOR MACHINE FOR *GENRE* CLASSIFICATION OF MUSIC

I Gusti Agung Dian Wintara¹ Rita Magdalena,Ir.,MT.² I Nyoman Apraz Ramatryana,ST.,MT.³

^{1,2,3}Prodi S1 Teknik Telekomunikasi,Fakultas Teknik Elektro,Universitas Telkom

¹dianwin@telkomuniversity.ac.id,²ritamagdalen@telkomuniversity.ac.id,³ramatryana@telkomuniversity.ac.id

Abstrak

Seiring dengan perkembangan zaman, dalam kurun waktu yang relatif singkat musik berkembang dengan begitu cepat. Musik memiliki berbagai macam jenis *genre* antara lain: *Classical, Rock, Reggae, Country*, dan *Jazz*. *Genre* musik adalah kategori dari karya seni, dalam hal ini khususnya musik, untuk mencirikan dan mengkategorikan musik yang kini tersedia dalam berbagai bentuk dan sumber. Pengklasifikasian *genre* musik secara otomatis dapat menjadi hal yang sangat membantu dalam pengembangan sistem temu-kembali untuk data audio. Pengolahan Sinyal *Digital* pada sinyal audio berkembang pesat untuk menghasilkan sebuah sistem yang bekerja secara digital. Sehingga diperlukan suatu pengembangan metode dan algoritma yang dapat mengklasifikasi *genre* secara tepat. Pada tugas akhir ini diteliti dengan menggunakan metode klasifikasi *Support Vector Machine*. Metode *Support Vector Machine* merupakan metode klasifikasi yang sederhana. Pembentukan model klasifikasi *Support Vector Machine* dengan mengumpulkan ciri dari data latih atau data acuan untuk menjadi data training saat pengujian. Dimana proses klasifikasi *genre* dimulai dengan memilih *file* lagu yang akan di klasifikasikan *genre*-nya, selanjutnya dilakukan proses *preprocessing*, pengambilan ciri dengan memanfaatkan ekstraksi ciri, dan terakhir proses klasifikasi *Support Vector Machine* untuk menghasilkan jenis *genre* dari *file* lagu yang dipilih. Pengujian yang dilakukan adalah pengujian terhadap metode klasifikasi *genre* menggunakan *Support Vector Machine*. Skenario pengujian dilakukan dengan jumlah data acuan 50 tiap-tiap *genre*, jumlah data uji 50 tiap-tiap *genre*.

Kata kunci: Klasifikasi, *genre* musik, *Support Vector Machine*

Abstract

Along with the times, music evolves quickly within a relatively short time. Music has a whole range of genres such as: *Classical, Rock, Reggae, Country*, dan *Jazz*. The music genre is a category of works of art, in this case especially music, to characterize and categorize the music is now available in various forms and sources. Automatically classifying musical genre can be very helpful in the development of retrieval system for audio data. Digital Signal Processing in the scope of audio signal is evolving rapidly, in terms to produce a system that works digitally. So we need a development of methods and algorithms that can accurately classify genre. In this Final Project studied the methods of classification using *Support Vector Machine*. *Support Vector Machine* method is a simple classification method. Establishment of classification models *Support Vector Machine* to collect characteristic of training data or reference data to be training data during testing. Where the genre classification process begins with choosing the song files will be classified its genre, then performed the process of preprocessing, retrieval characteristics by using feature extraction, and final classification process *Support Vector Machine* to produce the kind of genre of the selected song file. This Experiment is testing the genre classification method using *Support Vector Machine*. From test scenarios for the amount of reference data is 50 each genre, the number of test data is 50 each genre.

Keywords: Classification, music genre, *Support Vector Machine*

1. Pendahuluan

Musik terdiri dari berbagai macam *genre* dan jenis sesuai dengan konten musik tersebut yang umumnya mudah bagi pendengar manusia untuk membedakan tetapi sulit dibedakan oleh komputer. Keterbatasan tersebut mendorong diciptakannya klasifikasi *genre* untuk perkembangan musik digital. Klasifikasi *genre* dapat mempermudah dalam mempelajari dan mencari suatu lagu. Hal tersebut mendorong diciptakannya kemudahan dalam variasi klasifikasi *genre* yang mampu mengoptimalkan proses pembelajaran yang dapat dilakukan dengan mudah, *simple* dan memiliki kualitas yang baik dalam ketepatan pencarian suatu lagu. Sehingga diperlukan suatu pengembangan proses pembelajaran tersebut dengan berbagai metode dan algoritma yang lebih baik. Dalam perkembangannya dibatasi terlebih dahulu hanya pada klasifikasi *genre* yang memiliki kualitas yang baik dalam ketepatan klasifikasinya.

2. Dasar Teori

2.1 Musik

Musik adalah bunyi yang berasal dari alat musik maupun bukan alat musik. Musik terbagi atas 2 jenis ditinjau dari ada tidaknya suatu lirik yaitu musik yang memiliki lirik yang disebut dengan lagu dan musik yang tidak ada lirik atau yang biasa di kenal dengan instrumental. Musik digital merupakan salah satu data penting

yang di distribusikan melalui internet. Namun masih sulit untuk megklasifikasikan music berdasarkan jenisnya.[1]

Musik terbentuk atas tiga unsur, yaitu melodi, ritme dan harmoni. Melodi adalah rangkaian nada-nada yang tersusun atau teratur tinggi rendahnya sehingga menjadi sebuah lagu. Memainkan melodi sama dengan memainkan notasi-notasi dalam kerangka notasi lagu tanpa lirik (disebut dengan instrumental). Ritme adalah fondasi dari musik atau derap langkah iringan dalam sebuah lagu sehingga menjadi berbagai macam pola irama yang dapat memunculkan beragam *genre* musik. Harmoni adalah menyelaraskan antara melodi dan ritme atau menyusun suatu nada dengan menyisipkan hiasan-hiasan (*ornament*) dan dinamika sehingga bisa melodi dalam lagu bisa dimainkan dengan keras, lembut, bergelombang ataupun bergetar.

2.2 Genre

Genre adalah pengelompokan musik sesuai dengan kemiripannya satu sama lain atau karakteristik dari sebuah musik yang terbentuk berdasarkan jenis *instrument* yang digunakan, kulturasi daerah dan keadaan geografis [2]. Kata *genre* berasal dari bahasa latin *genus*, yang berarti jenis atau kelas. Setiap *genre* memiliki *pattern* yang unik, misalnya bunyi yang khas dari gitar, bass, drum, ataupun instrument musik elektronik. Berikut adalah pembahasan mengenai *genre* musik yang digunakan dalam penulisan Tugas Akhir.

2.2.1 Rock

Musik *Rock*[3] adalah *genre* musik populer yang mulai diketahui secara umum pada pertengahan tahun '50-an. Akarnya berasal dari *rythim* dan *blues*, musik *country* dari tahun '40 dan '50-an serta berbagai pengaruh lainnya. Selanjutnya, musik *rock* juga mengambil gaya dari berbagai musik lainnya, termasuk musik rakyat (*folk music*), *jazz* dan musik klasik.

Bunyi khas dari musik *rock* sering berkisar sekitar gitar listrik atau gitar akustik, dan penggunaan *backbeat* yang sangat kentara pada *rhythm section* dengan gitar, *bass*, dandrum, dan kibor seperti organ, piano atau sejak '70-an, *synthesizer*. Disamping gitar atau kibor, saksofon dan *harmonica* bergaya blues kadang digunakan sebagai instrument musik solo. Dalam bentuk murninya, musik *rock* mempunyai tiga *chords*, *backbeat* yang konsisten dan mencolok dan melodi yang menarik.

2.2.2 Country

Musik *country*[3] adalah campuran dari sejumlah unsur musik Amerika yang berasal dari Amerika Serikat Bagian Selatan dan Pegunungan *Appalachia*. Musik ini berakar dari lagu rakyat Amerika Utara, musik kelt, musik gospel, dan berkembang sejak tahun 1920-an. Istilah musik *country* mulai dipakai sekitar tahun 1940-an untuk menggantikan istilah musik *hillbilly* yang berkesan merendahkan. Pada tahun 1970-an, istilah musik *country* telah menjadi istilah populer.

2.2.3 Classical

Musik *Classical*[3] adalah komposisi musik yang lahir dari budaya Eropa sekitar tahun 1750-1825. Musik ini biasanya didominasi instrumen klasik seperti biola, cello, piano, flute, dan lain sebagainya. Pada era inilah nama-nama besar seperti *Bach*, *Mozart*, atau *Haydn* melahirkan karya-karyanya yang berupa sonata, simfoni, konserto solo, string kuartet, hingga opera. Namun pada kenyataannya, para komposer klasik sendiri tidak pernah menggolong-golongkan jenis komposisi yang mereka gubah. Penggolongan yang kita kenal sekarang dilakukan semata-mata untuk mempermudah, terutama untuk kepentingan akademis.

2.2.4 Reggae

Musik *Reggae*[3] adalah suatu aliran musik yang awalnya dikembangkan di Jamaika pada akhir era 60-an. Sekalipun kerap digunakan secara luas untuk menyebut hampir segala jenis musik Jamaika, istilah *reggae* lebih tepatnya merujuk pada gaya musik khusus yang muncul mengikuti perkembangan *ska* dan *rocksteady*. Pada umumnya *reggae* memiliki tempo lebih lambat daripada *ska* maupun *rocksteady*. Biasanya dalam *reggae* terdapat aksentuasi pada ketukan kedua dan keempat pada setiap bar, dengan gitar *rhythm* juga memberi penekanan pada ketukan ketiga atau menahan kord pada ketukan kedua sampai ketukan keempat dimainkan. Utamanya ketukan ketiga tersebut, selain tempo dan permainan bassnya yang kompleks yang membedakan *reggae* dari *rocksteady*, meskipun *rocksteady* memadukan pembaruan-pembaruan tersebut secara terpisah.

2.2.5 Jazz

Musik *Jazz*[3] adalah aliran musik yang berasal dari Amerika Serikat pada awal abad ke-20 dengan akar-akar dari musik Afrika dan Eropa. Musik *jazz* banyak menggunakan gitar, trombon, piano, terompet, dan saksofon. Elemen penting dalam *jazz* adalah *bluenotes*, improvisasi, *polyrhythms*, sinkopasi, dan *shufflenote*.

2.3 Support Vector Machine

Support Vector Machine (SVM) merupakan teknik yang relatif baru untuk melakukan prediksi, baik dalam kasus klasifikasi maupun *regresi*. SVM menemukan solusi *global optima*, oleh karena itu SVM selalu mencapai solusi yang sama untuk setiap *running*. Ide dasar SVM adalah berusaha menemukan fungsi pemisah (*classifier*) yang optimal yang dapat memisahkan dua jenis data dari dua kelas yang berbeda[4].

2.3.1 Karakteristik Support Vector Machine (SVM)[7]

Karakteristik SVM secara umum sebagai berikut:

1. Secara prinsip SVM adalah linear classifier.
2. Pengenalan pola (Pattern recognition) dilakukan dengan mentransformasikan data pada input space ke ruang yang berdimensi lebih tinggi, dan optimisasi dilakukan pada ruang vektor yang baru tersebut. Hal ini membedakan SVM dari solusi pattern recognition pada umumnya, yang melakukan optimisasi parameter pada ruang hasil transformasi yang berdimensi lebih rendah daripada dimensi input space.
3. Menerapkan strategi *Structural Risk Minimization* (SRM).
4. Prinsip kerja SVM hanya mampu menangani klasifikasi dua kelas.

2.3.2 Kelebihan dan kekurangan Support Vector Machine(SVM)[7]

Kelebihan dari metode SVM adalah sebagai berikut:

1. Generalisasi

Generalisasi didefinisikan sebagai kemampuan suatu metode untuk mengklasifikasikan suatu *pattern*, dan tidak termasuk data yang dipakai dalam fase pembelajaran metode itu.

2. Curse of dimensionality (COD)

Curse of dimensionality didefinisikan sebagai masalah yang dihadapi suatu metode *pattern recognition* dalam mengestimasi parameter dikarenakan jumlah sampel data yang relatif lebih sedikit dibandingkan dengan dimensional ruang vektor data tersebut. Semakin tinggi dimensi dari ruang vektor informasi yang diolah, membawa konsekuensi dibutuhkannya jumlah data dalam proses pembelajaran. *Curse of dimensionality* sering dialami dalam aplikasi di bidang *biomedical engineering*, karena biasanya data biologi yang tersedia sangat terbatas, dan penyediaannya memerlukan biaya tinggi. Vapnik membuktikan bahwa tingkat generalisasi yang diperoleh oleh SVM tidak dipengaruhi oleh dimensi dari *input vector*. Hal ini merupakan alasan mengapa SVM merupakan salah satu metode yang tepat dipakai untuk memecahkan masalah berdimensi tinggi, dalam keterbatasan sampel data yang ada.

3. Feasibility

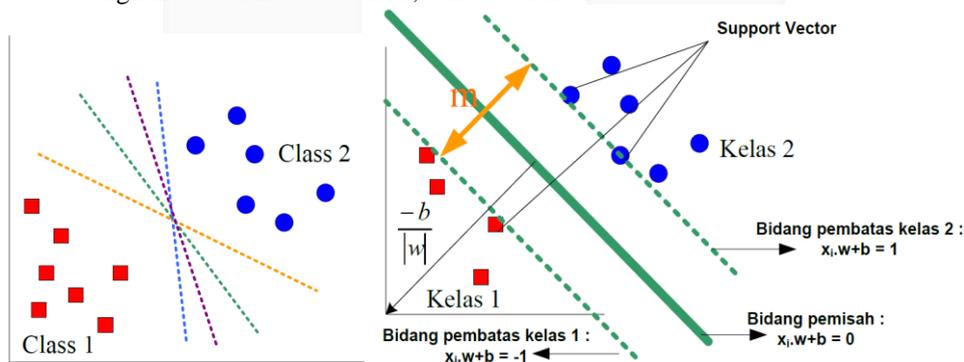
SVM dapat diimplementasikan relatif mudah, karena proses penentuan support vector dapat dirumuskan dalam QP(*Quadratic Programming*) *problem*. Dengan demikian jika kita memiliki library untuk menyelesaikan QP *problem*, dengan sendirinya SVM dapat diimplementasikan dengan mudah.

Kekurangan dari metode SVM adalah sebagai berikut:

1. Sulit dipakai problem berskala besar. Dalam hal ini dimaksudkan dengan jumlah sampel yang diolah.
2. SVM secara teoritik dikembangkan untuk problem klasifikasi dengan dua kelas. Dewasa ini SVM telah dimodifikasi agar dapat menyelesaikan masalah dengan class lebih dari dua, antara lain strategi *One Against All* dan *One Against One*.

2.3.3 SVM pada Linearly Separable Data

Linearly separable data[4] merupakan data yang dapat dipisahkan secara linier. Misalkan $\{x_1, \dots, x_n\}$ adalah data set dan $y_i \in \{+1, -1\}$ adalah label kelas dari data x_i , untuk $i = 1, 2, 3, \dots, n$, dimana n adalah banyaknya data. Sedangkan w adalah bobot vektor, dan b adalah bias.



Gambar 2.2 Alternatif bidang pemisah (kiri) dan bidang pemisah terbaik dengan margin (m) terbesar (kanan)

Diasumsikan kedua kelas -1 dan 1 dapat terpisah secara sempurna oleh fungsi pemisah (*hyperplane*) berdimensi d , yang didefinisikan sebagai berikut[4]:

$$w \cdot x + b = 0 \tag{2.1}$$

Permasalahan ini dapat dipecahkan dengan mengubah ke dalam formula *Langrangian primal problem*. Sehingga persamaan menjadi[4]:

$$\min_{w,b} L_p(w, b, a) = \frac{1}{2} |w|^2 - \sum_{i=1}^n a_i y_i (x_i \cdot w + b) + \sum_{i=1}^n a_i \tag{2.2}$$

a_i adalah koefisien *langrange* dan $a_i \geq 0$. Nilai optimal dari persamaan (2.2) dapat dihitung dengan meminimalkan L_p terhadap w dan b kemudian mensubstitusikannya ke dalam formula *Langrangian dual problem* dan memaksimumkannya terhadap a_i . Sehingga persamaan diubah menjadi[4]:

$$\max_a L_D \equiv \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1,j=1}^n a_i a_j y_i y_j x_i \cdot x_j \tag{2.3}$$

Dimana[4]:

$$(a_i \geq 0), (i = 1, 2, \dots, l) \sum_{i=1}^n a_i y_i = 0 \tag{2.4}$$

Setiap data pelatihan memiliki nilai a_i , dimana data latih dengan nilai $a_i \geq 0$ merupakan *support vector* yang dapat mempengaruhi fungsi keputusan. Setelah solusi permasalahan *quadratic programming* ini ditemukan (nilai a_i), maka kelas dari data x_i dapat ditentukan berdasarkan nilai dari fungsi keputusan[4]:

$$f(x_d) = \sum_{i=1}^{ns} a_i y_i x_i x_d + b \tag{2.5}$$

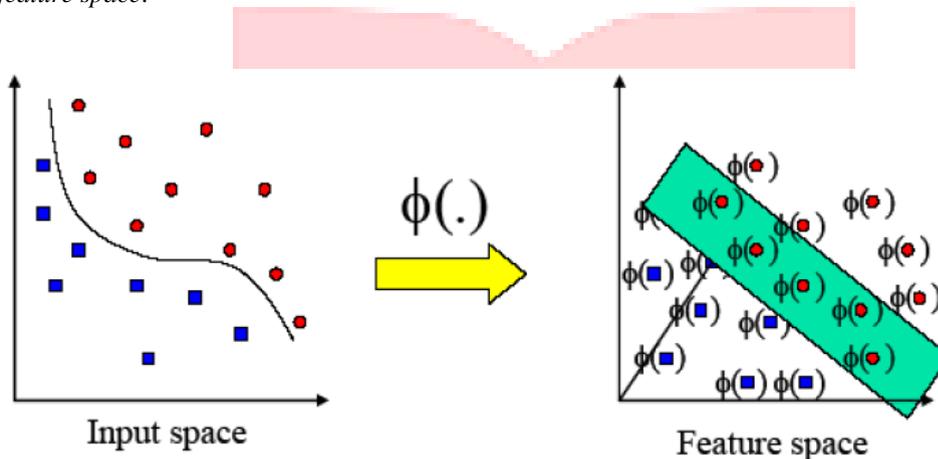
Dimana x_i adalah *support vector*, ns = jumlah *support vector*, dan x_d adalah data yang akan diklasifikasikan.

2.3.4 SVM pada Nonlinearly Separable Data

SVM pada *Nonlinearly Separable Data*[4] adalah suatu pendekatan yang dapat dilakukan untuk data yang tidak dapat dipisahkan secara linier yaitu dengan mentransformasikan data ke dalam dimensi ruang fitur(*feature space*) sehingga dapat dipisahkan secara linier pada *feature space*.

Untuk mengklasifikasikan data yang tidak dapat dipisahkan secara linier formula SVM harus dimodifikasi karena tidak akan ada solusi yang ditemukan. Oleh karena itu, kedua bidang pembatas harus diubah sehingga lebih fleksibel.

Metode lain untuk mengklasifikasikan data yang tidak dapat dipisahkan secara linier adalah dengan mentransformasikan data ke dalam dimensi ruang fitur(*feature space*) sehingga dapat dipisahkan secara linier pada *feature space*.

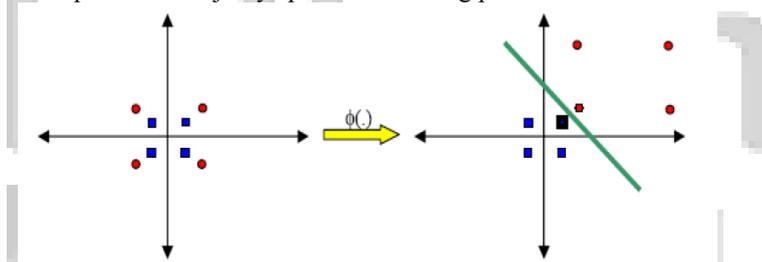


Gambar 2.3 Transformasi dari vektor input ke *feature space*

Caranya, data dipetakan dengan menggunakan fungsi pemetaan (transformasi) $x_k \rightarrow \varphi(x_k)$ ke dalam *feature space* sehingga terdapat bidang pemisah yang dapat memisahkan data sesuai dengan kelasnya (seperti pada gambar). Misalkan terdapat data set yang datanya memiliki dua atribut dan dua kelas yaitu kelas positif dan negatif. Data yang memiliki kelas positif adalah $\{(2,2),(2,-2),(-2,2),(-2,-2)\}$, dan data yang memiliki kelas negatif $\{(1,1),(1,-1),(-1,1),(-1,-1)\}$. Apabila data ini digambarkan dalam ruang dua dimensi dapat dilihat data ini tidak dapat dipisahkan secara linier. Oleh karena itu, digunakan fungsi transformasi berikut[4]:

$$\varphi(x_1, x_2) = \left\{ \begin{array}{l} \sqrt{x_1^2 + x_2^2} > 2 \rightarrow (4 - x_2 + |x_1 - x_2|, 4 - x_1 + |x_1 - x_2|) \\ \sqrt{x_1^2 + x_2^2} \leq 2 \rightarrow (x_1, x_2) \end{array} \right\} \tag{2.6}$$

Data sesudah transformasi adalah $\{(6,2), (6,6), (2,6), (2,2)\}$ untuk kelas negatif, dan $\{(1,1), (1,-1), (-1,1), (-1,-1)\}$ untuk kelas positif. Selanjutnya pencarian bidang pemisah terbaik dilakukan pada data ini.



Gambar 2.4 Transformasi untuk data yang tidak dapat dipisahkan secara linear

2.3.6 Multiclass SVM

Pada saat pertama kali diperkenalkan oleh Vapnik, SVM hanya dapat mengklasifikasikan data menjadi dua kelas (klasifikasi *binary*). Salah satu cara untuk mengimplementasikan *multiclass SVM* yaitu dengan mengkombinasikan beberapa SVM *binary*. Beberapa metode untuk kombinasi yang dapat digunakan antara lain:

1. One-against-all

Dibangun sejumlah k SVM *binary*, dengan k adalah jumlah kelas. Contohnya, untuk persoalan klasifikasi dengan 5 buah jumlah kelas, digunakan 5 buah SVM *binary* pada tabel di bawah ini dan penggunaannya pada pengklasifikasian data baru.

2. One-against-one

Dibangun sejumlah $\frac{k(k-1)}{2}$ buah model SVM *binary*, dengan k adalah jumlah kelas. Contohnya, untuk masalah klasifikasi dengan 5 buah jumlah kelas, digunakan 10 buah SVM *binary* pada tabel di bawah ini dan penggunaannya pada pengklasifikasian data baru.

2.3 Parameter Pengujian

2.3.1 Akurasi

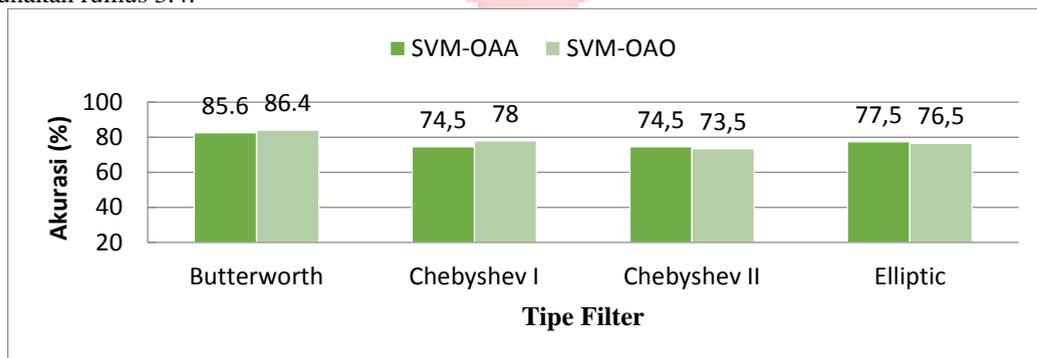
Sistem yang telah dibuat akan diuji parameter-parameternya dengan beberapa data uji. Kemudian akan diukur tingkat akurasi sistem dalam mengenali *genre* serta waktu kerja sistem. Untuk perhitungan akurasi digunakan rumus sebagai berikut:

$$\text{Akurasi} = \frac{\text{Jumlah data benar}}{\text{Jumlah data}} \times 100\% \quad (3.4)$$

3 Analisis

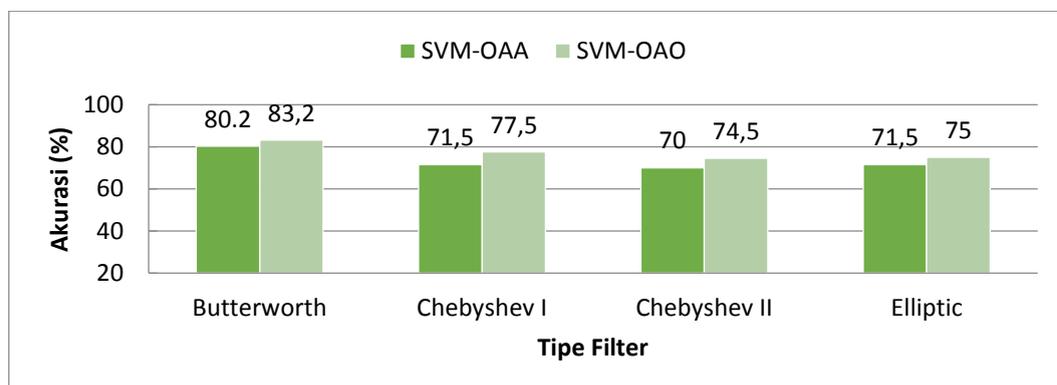
3.1 Pengaruh Tipe Filter dan Orde Filter Terhadap Akurasi Output Sistem

Untuk menganalisis pengaruh tipe filter terhadap akurasi *output* sistem terdapat beberapa skenario yang diujikan. Dalam skenario ini dilakukan pengujian empat tipe filter yaitu *Butterworth*, *Chebyshev I*, *Chebyshev II* dan *Elliptic* dengan nilai orde yaitu orde 3, 4, dan 5. Dalam pengujian digunakan data latih sebanyak 50 data lagu tiap-tiap genre dan 50 data lagu tiap-tiap genre sebagai data uji. Dari hasil pengujian, dilakukan analisis akurasi menggunakan rumus 3.4.



Gambar 3.1 Perbandingan Tipe Filter Saat Orde Filter 3 Terhadap Akurasi Output Sistem

Dari gambar 3.1 Perbandingan Tipe *Filter* saat Orde *Filter* 3 Terhadap Akurasi *Output* sistem didapatkan tipe filter terbaik yaitu *Butterworth*. Tipe tersebut mempunyai akurasi terbaik saat menggunakan orde 3 dengan akurasi sebesar 85,6% pada sistem klasifikasi SVM-OAA dan akurasi sebesar 86,4% pada sistem klasifikasi SVM-OAO. Hasil analisis dari pengujian perbandingan tipe filter saat orde filter 3 terhadap akurasi *output* sistem adalah untuk tipe filter *Butterworth* yang tidak memiliki *ripple* pada sisi *passband* maupun *stopband* memiliki akurasi terbaik, sedangkan untuk *Chebyshev I* yang memiliki *ripple* disisi *passband* memiliki akurasi terbaik kedua saat kondisi orde filter 3 dengan sistem klasifikasi yang sama. Dapat dianalisis bahwa akurasi tertinggi saat orde filter 3 yang sangat berpengaruh pada sistem adalah jenis filter yang bekerja baik pada sisi *passband* dan *stopband*nya.

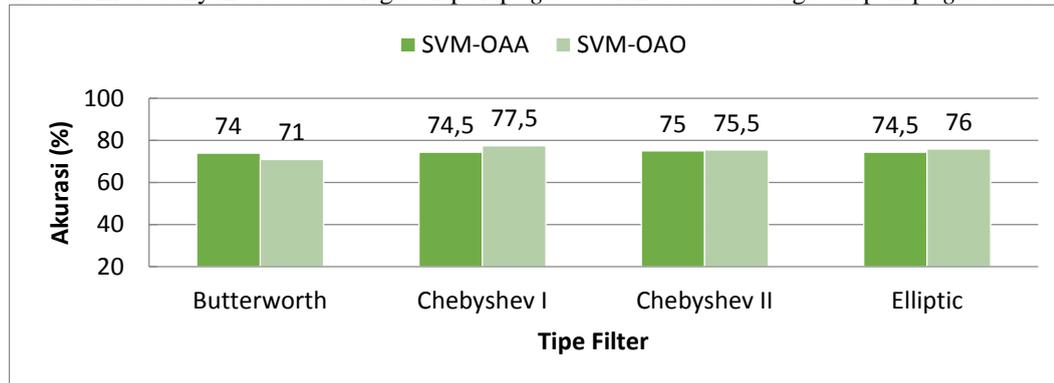


Gambar 3.2 Perbandingan Tipe Filter Saat Orde Filter 4 Terhadap Akurasi Output Sistem

Dari gambar 3.2 Perbandingan Tipe *Filter* saat Orde *Filter* 4 Terhadap Akurasi *Output* sistem didapat tipe filter terbaik yaitu *Butterworth*. Tipe tersebut mempunyai akurasi terbaik saat kondisi orde 4 yaitu akurasi sebesar 80,2% dengan sistem klasifikasi SVM-OAA dan akurasi sebesar 83,2% dengan sistem klasifikasi SVM-OAO. Hasil analisis dari pengujian perbandingan tipe filter saat orde filter 4 terhadap akurasi *output* sistem adalah untuk tipe filter *Butterworth* yang tidak memiliki *ripple* pada sisi *passband* maupun *stopband* memiliki akurasi terbaik, sedangkan untuk *Chebyshev I* yang memiliki *ripple* disisi *passband* memiliki akurasi terbaik kedua saat kondisi orde filter 4 dengan sistem klasifikasi yang sama. Dapat dianalisis bahwa akurasi tertinggi saat orde filter 4 yang sangat berpengaruh pada sistem adalah jenis filter yang bekerja baik pada sisi *passband* dan *stopband*nya.

Perancangan filter *Buterworth* untuk orde yang semakin besar menyebabkan daerah transisi antara *passband* dan *stopband* akan semakin sempit. Orde semakin besar akan berdampak *pole* akan semakin banyak sehingga untuk orde yang semakin besar juga dapat menyebabkan filter semakin tidak stabil karena *pole* akan keluar dari lingkaran satuan.

Selanjutnya dilakukan pengujian dengan perbandingan tipe filter saat orde filter 5 dengan metode klasifikasi *Support Vector Machine One Against All* dan *Support Vector Machine One Against One*. Menggunakan data latih sebanyak 50 data lagu tiap-tiap *genre* dan 50 data lagu tiap-tiap *genre* sebagai data uji.



Gambar 3.3 Perbandingan Tipe Filter Saat Orde Filter 5 Terhadap Akurasi Output Sistem

Dari gambar 3.3 Perbandingan Tipe Filter saat Orde Filter 5 Terhadap Akurasi Output sistem didapat tipe filter terbaik untuk sistem klasifikasi SVM-OAA yaitu *Chebyshev II* dengan akurasi sebesar 75% dan untuk sistem klasifikasi SVM-OAO yaitu *Chebyshev I* dengan akurasi sebesar 77,5%. Hasil analisis dari pengujian perbandingan tipe filter saat orde filter 5 terhadap akurasi output sistem adalah untuk tipe filter *Chebyshev II* yang memiliki *ripple* pada sisi *stopband* memiliki akurasi terbaik dengan sistem klasifikasi SVM-OAA, sedangkan untuk *Chebyshev I* yang memiliki *ripple* disisi *passband* memiliki akurasi terbaik dengan sistem klasifikasi SVM-OAO.

3.2 Pengaruh Banyak Data Latih dan Data Uji Terhadap Akurasi Output Sistem

Dalam skenario ini dilakukan pengujian yaitu 10, 20, 30, 40 dan 50 data latih untuk tiap-tiap *genre* dan digunakan data uji sebanyak 10 data lagu untuk tiap-tiap *genre*. Menggunakan *epoch*10 untuk sistem klasifikasi SVM menggunakan parameter yaitu jenis *kernel polynomial*, *kerneloption* 1, nilai C 10 dan nilai epsilon 10^{-2} . Dari hasil pengujian, dilakukan analisis akurasi menggunakan rumus 3.4.

Tabel 3.1 Hasil klasifikasi SVM menggunakan 10 data uji

| Data Uji | Waktu uji | Akurasi OAA (%) |
|----------|-----------|-----------------|
| 10 | 0,6676 | 66 |
| 10 | 0,7425 | 68 |
| 10 | 0,7920 | 72 |
| 10 | 0,7877 | 72 |
| 10 | 0,9264 | 78 |

Selanjutnya dilakukan pengujian 10, 20, 30, 40 dan 50 data latih untuk tiap-tiap *genre* dan digunakan data uji sebanyak 20 data lagu untuk tiap-tiap *genre*. Dari hasil pengujian, dilakukan analisis akurasi menggunakan rumus 3.4.

Tabel 3.2 Hasil klasifikasi SVM menggunakan 20 data uji

| Data Uji | Waktu uji | Akurasi OAA (%) | Akurasi OAO (%) |
|----------|-----------|-----------------|-----------------|
| 20 | 0,6292 | 69 | 79 |
| 20 | 0,6932 | 72 | 76 |
| 20 | 0,7590 | 74 | 74 |
| 20 | 0,7805 | 73 | 83 |
| 20 | 0,8762 | 80 | 83 |

Selanjutnya dilakukan pengujian lima banyak data latih yaitu 10, 20, 30, 40 dan 50. Dalam pengujian digunakan data uji sebanyak 30 data lagu tiap-tiap *genre*. Dari hasil pengujian, dilakukan analisis akurasi menggunakan rumus 3.4.

Tabel 3.3 Hasil klasifikasi SVM menggunakan 30 data uji

| Data Uji | Waktu uji | Akurasi (%) |
|----------|-----------|-------------|
| 30 | 0,6339 | 73,33 |
| 30 | 0,7212 | 75,35 |
| 30 | 0,7994 | 77,33 |
| 30 | 0,8654 | 76 |
| 30 | 0,8724 | 80,67 |

Selanjutnya dilakukan pengujian lima banyak data latih yaitu 10, 20, 30, 40 dan 50. Dalam pengujian digunakan data uji sebanyak 40 data lagu tiap-tiap genre. Dari hasil pengujian, dilakukan analisis akurasi menggunakan rumus 3.4

Tabel 3.4 Hasil klasifikasi LDA menggunakan 40 data uji

| Data Uji | Waktu uji | Akurasi (%) |
|----------|-----------|-------------|
| 40 | 0,6498 | 75,5 |
| 40 | 0,7293 | 76 |
| 40 | 0,7874 | 78,5 |
| 40 | 0,7738 | 79,5 |
| 40 | 0,8956 | 80,5 |

Selanjutnya dilakukan pengujian lima banyak data latih yaitu 10, 20, 30, 40 dan 50. Dalam pengujian digunakan data uji sebanyak 50 data lagu tiap-tiap genre. Dari hasil pengujian, dilakukan analisis akurasi menggunakan rumus 3.4

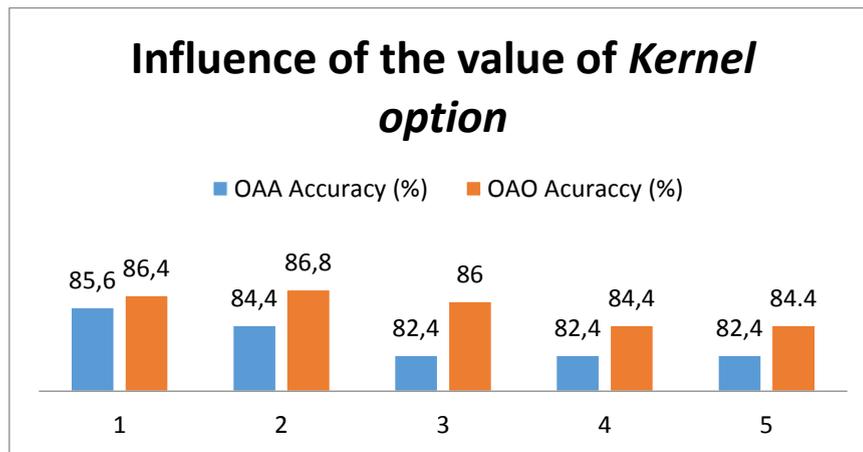
Tabel 3.5 Hasil klasifikasi LDA menggunakan 50 data uji

| Data Uji | Waktu uji | Akurasi (%) |
|----------|-----------|-------------|
| 50 | 0,6484 | 76,4 |
| 50 | 0,7460 | 78,4 |
| 50 | 0,7566 | 80,8 |
| 50 | 0,8371 | 81,6 |
| 50 | 0,8277 | 85,6 |

3.3 Pengujian dan Analisis Metode Klasifikasi SVM Terhadap Akurasi Output Sistem

3.3.1 Pengaruh *Kerneloption*

Dalam skenario ini dilakukan lima pengujian nilai *kernel option* 1, 2, 3, 4 dan 5. Pelatihan SVM menggunakan parameter yaitu jenis *kernel polynomial*, nilai C 10, dan nilai epsilon 10^{-1} . Data uji yang digunakan 50 tiap-tiap genre sehingga total data uji sejumlah 200 data uji. Dari hasil pengujian, dilakukan analisis akurasi menggunakan rumus 3.1.

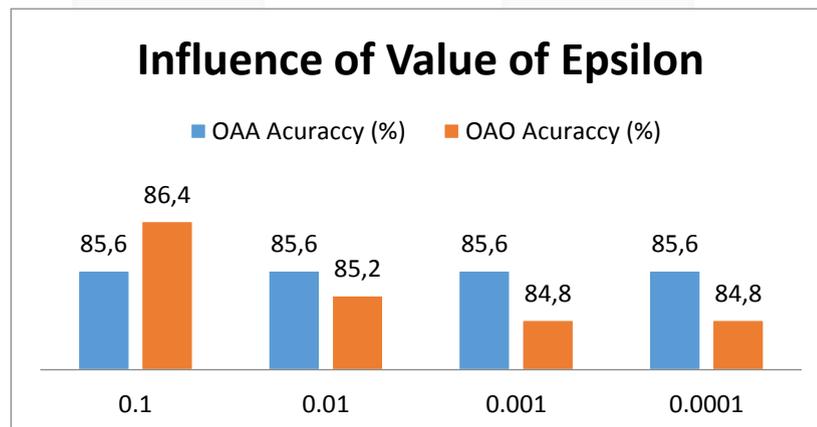


Gambar 4.1 Pengaruh Nilai Kernel option

Dari hasil pengujian pada gambar 4.6, didapat perubahan nilai akurasi di setiap nilai *kernel option*, sehingga didapat nilai akurasi yang terbaik adalah saat $K = 1$ dengan nilai akurasi 85,6% dan 86,4%.

3.3.2 Pengaruh nilai Epsilon

Dalam skenario ini dilakukan pengujian nilai *epsilon*. Pelatihan SVM menggunakan parameter yaitu jenis *kernel polynomial*, *kernel option* 1 dan nilai C sebesar 10. Data uji yang digunakan 50 tiap-tiap genre sehingga total data uji sejumlah 250 data uji. Dari hasil pengujian, dilakukan analisis akurasi menggunakan rumus 3.1.



Gambar 4.2 Pengaruh Nilai Epsilon

Disimpulkan dari tabel 4.7, nilai *epsilon* pada nilai 10^{-1} memiliki akurasi yang paling baik, sedangkan pada nilai *epsilon* 10^{-2} mengalami penurunan akurasi menjadi 85,6% dan 85,2%. Dan nilai *epsilon* pada nilai 10^{-3} sampai dengan nilai 10^{-4} mengalami penurunan juga dan memiliki nilai sama yaitu 85,6% dan 84,8%.

3.4 Hasil Pengujian dan Analisis Metode SVM Menggunakan Tabel Confusion Matrix.

Dalam pengujian digunakan data uji sebanyak 50 data lagu tiap-tiap genre. Dari hasil pengujian, dilakukan analisis akurasi menggunakan rumus 3.1.

Tabel 4.8 Hasil Klasifikasi SVM-OAA menggunakan Confusion Matrix

| Genre | Classical | Country | Jazz | Reggae | Rock | Akurasi (%) |
|-----------|-----------|---------|------|--------|------|-------------|
| Classical | 42 | 2 | 4 | 0 | 2 | 84 |
| Country | 0 | 42 | 6 | 0 | 2 | 84 |
| Jazz | 3 | 1 | 44 | 2 | 1 | 88 |
| Reggae | 0 | 5 | 2 | 41 | 2 | 82 |
| Rock | 1 | 3 | 1 | 0 | 45 | 90 |

Dari tabel 4.8 didapat akurasi terbaik dalam sistem klasifikasi SVM-OAA pada *Genre Rock* dengan akurasi 90% dan akurasi rata rata sebesar 85.6%.

Tabel 4.9 Hasil Klasifikasi SVM-OAO menggunakan Confusion Matrix

| Genre | Classical | Country | Jazz | Reggae | Rock | Akurasi (%) |
|-----------|-----------|---------|------|--------|------|-------------|
| Classical | 47 | 2 | 1 | 0 | 0 | 94 |
| Country | 0 | 42 | 6 | 0 | 2 | 84 |
| Jazz | 4 | 1 | 42 | 2 | 1 | 84 |
| Reggae | 0 | 0 | 1 | 46 | 3 | 92 |
| Rock | 1 | 3 | 3 | 2 | 41 | 82 |

Dari tabel 4.9 didapat akurasi terbaik dalam sistem klasifikasi SVM-OAO pada *Genre Classical* dengan akurasi 94% dan akurasi rata rata sebesar 86.4%.

4. Kesimpulan

Berdasarkan hasil implementasi, pengujian, dan analisis yang telah dilakukan, maka dapat ditarik kesimpulan sebagai berikut :

1. Tipe *filter* yang memiliki akurasi terbaik saat menggunakan metode klasifikasi *Support Vector Machine* OAA adalah tipe filter *Butterworth* orde 3 yang memiliki akurasi 85,6%, dan metode klasifikasi *Support Vector Machine* OAO adalah tipe filter *Butterworth* orde 3 yang memiliki akurasi 86.4%.
2. Setelah dilakukan pengujian terhadap klasifikasi 5 genre lagu yaitu *Classical*, *Country*, *Jazz*, *Reggae* dan *Rock*, metode *Support Vector Machine* OAA akurasi tertingginya adalah 85.6% untuk jumlah data latih 50 tiap-tiap genre, 50 data uji tiap-tiap genre, menggunakan parameter yaitu jenis *kernel polynomial*, *kerneloption* 1, nilai epsilon 10^{-1} dan nilai $C=10$. Metode *Support Vector Machine* OAO akurasi tertinggi adalah 86.4% untuk jumlah data latih 50 tiap-tiap genre, 50 data uji tiap-tiap genre, menggunakan parameter yaitu jenis *kernel polynomial*, *kerneloption* 1, nilai epsilon 10^{-1} dan nilai $C=10$.

Daftar Pustaka

- [1] Betteng, Rico Chrisnawan. 2012. *Content Based Filtering Musik Information Retrieval Berdasarkan Genre, Mood dan Nada Dasar dengan Inputan Audio*. Bandung: Institut Teknologi Telkom.
- [2] Barbedo, J.G.A. and Lopes, A. 2007. *Automatic Genre Classification of Musical Signals*. *EURASIP Journal on Applied Signal Processing*.
- [3] Brigham, E. Organ. 1988. *The Fast Fourier Transform And Its Application*. Singapore: Prentice Hall, Inc
- [4] Gunn, S.R. 1998. *Support Vector Machines for Classification and Regression*. *ISIS technical report*.
- [5] Petty, Brendan. 2010. *Music Genre Classification using a Backpropagation Neural Network*. Labrosa
- [6] Hong, J.S. and Lancaster, M.J. 2000. *Design of Highly Selective Microstrip Bandpass Filters With a Single Pair of Attenuation Poles at Finite Frequencies*. *IEEE Transactions on Microwave Theory and Techniques*.
- [7] Toyyibatul Faihah, RA. 2010. Makalah *Data Mining Support Vector Machine (SVM)* [Online]. Tersedia: http://www.academia.edu/7304068/Makalah-svm_ra-toyyibatul-f_070411100132 [18 Oktober 2016]