

Klasifikasi Genre Musik Menggunakan Metode Support Vector Machine Dengan Multi-Kernel

I Gusti Agung Istri Agrivina Shyta Devi^{a1}, I Made Widiartha^{a2}

Program Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Udayana
Jalan Raya Kampus UNUD, Bukit Jimbaran, Kuta Selatan, Badung, Bali, Indonesia
¹gunggekshyta@email.com
²madewidiartha@unud.ac.id

Abstract

Music is a universal art that reflects cultural diversity and individual preferences through various genres. This research explores music genre classification using Support Vector Machine (SVM) with multi-kernel methods. The SVM algorithm, known for its effectiveness in handling complex datasets, is employed to classify music genres based on audio features. The research utilizes the GTZAN dataset, comprising 10 music genres, and extracts audio features from WAV files. After normalization and data splitting, SVM models are trained and evaluated. Results indicate a significant accuracy improvement after hyperparameter tuning, with the best models achieving accuracies of 88.92% for the polynomial kernel and 89.32% for the RBF kernel.

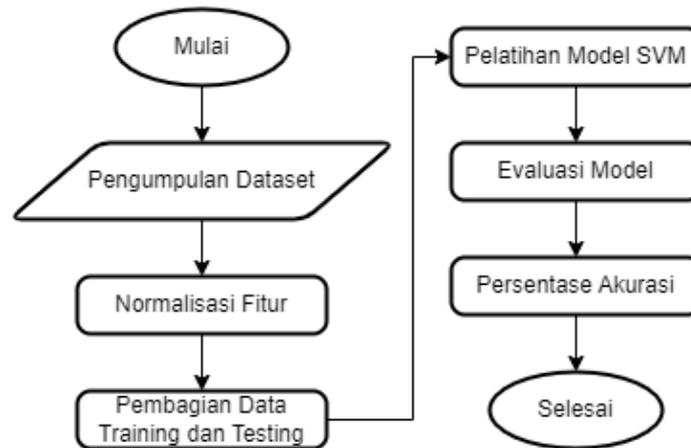
Keywords: Classification, Music Genre, SVM, Kernel Function

1. Pendahuluan

Musik merupakan sebuah seni yang universal, keberagaman genre musik merupakan cerminan dari keberagaman budaya dan selera dari setiap individu [1]. Klasifikasi genre musik adalah salah satu aplikasi umum dari analisis data audio. Hal ini melibatkan pengelompokan atau pengkategorian lagu-lagu berdasarkan karakteristik seperti tempo, melodi, harmoni, dan instrumen yang digunakan. Klasifikasi genre musik merupakan langkah penting dalam memahami dan mengorganisir keanekaragaman musik yang ada. Dengan membagi lagu-lagu ke dalam genre-genre yang berbeda, kita dapat lebih mudah mengidentifikasi dan menemukan jenis musik yang memenuhi keinginan dan preferensi kita. Selain itu, klasifikasi genre juga memungkinkan para pengamat musik, peneliti, dan profesional industri musik untuk menganalisis tren, memahami preferensi audiens, dan mengembangkan rekomendasi musik yang lebih tepat. Dalam era digital saat ini, klasifikasi genre musik juga menjadi kunci untuk pengembangan teknologi. Dari pemrosesan sinyal digital hingga kecerdasan buatan, pemahaman tentang genre musik membuka pintu untuk inovasi yang tak terbatas. Misalnya, algoritma yang mampu mengidentifikasi dan merekomendasikan musik berdasarkan preferensi pengguna dapat meningkatkan pengalaman mendengarkan musik secara signifikan. Salah satu algoritma yang telah terbukti efektif dalam tugas klasifikasi adalah Mesin Vektor Pendukung (Support Vector Machine/SVM). SVM menawarkan keunggulan dalam menangani masalah klasifikasi dengan banyak fitur dan kumpulan data yang kompleks, seperti yang sering ditemui dalam analisis data audio. Dalam jurnal penelitian dengan judul "Klasifikasi Genre Musik Menggunakan Teknik Pembelajaran Mesin" menyatakan bahwa jika dibandingkan dengan K-NN nilai akurasi dari SVM lebih tinggi yaitu 71%, sementara dengan K-NN sebesar 69,6% [6]. Selain itu, menurut Santosa dan Erwin SVM dapat mengatasi permasalahan multiclass [7].

2. Metode Penelitian

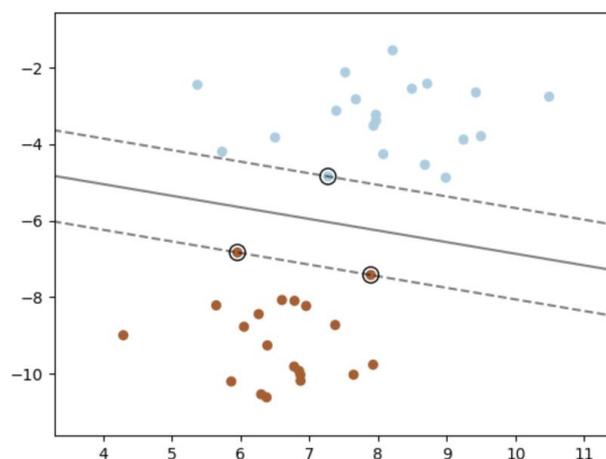
Dalam penelitian ini, ada prosedur yang harus dijalankan dalam mengklasifikasikan genre musik. Hal ini dimulai dari pengumpulan dataset sampai proses pelatihan model dan evaluasi.



Gambar 2. Flowchart Alur Penelitian

2.1 Support Vector Machine

Algoritma pembelajaran mesin Support Vector Machine (SVM) dapat digunakan untuk tugas regresi dan klasifikasi. Konsep Minimisasi Risiko Struktural (SRM) adalah dasar dari prinsip kerja SVM. Tujuan SRM adalah untuk menemukan Hyperplane yang memiliki kemampuan untuk memisahkan ruang input menjadi dua kelas. Teori SVM dimulai dengan mengklasifikasikan contoh-contoh dalam ruang linier yang dapat dibedakan oleh hyperplane dan dikelompokkan berdasarkan kelasnya. Ide dasar SVM dimulai dengan permasalahan klasifikasi biner yang memerlukan kumpulan data pelatihan yang terdiri dari sampel positif dan negatif. SVM akan berupaya mengoptimalkan pemilihan hyperplane sebagai pemisah antara kedua kelas dengan maksud untuk memaksimalkan margin antara kelas-kelas tersebut [4]. Satu atau lebih hyperplane dibangun dalam ruang yang besar atau tak terbatas oleh support vector machine. Ruang ini dapat digunakan untuk melakukan tugas seperti klasifikasi, regresi, atau lainnya. Hyperplane yang memiliki jarak terdekat ke titik data latih terdekat dari setiap kelas melakukan pemisahan yang efektif; biasanya, semakin besar jarak, semakin kecil kesalahan generalisasi yang dihasilkan oleh pengklasifikasi. Pada gambar 1 di bawah ini menunjukkan fungsi keputusan untuk masalah yang dapat dipisahkan secara linear, dengan tiga sampel di batas margin, yang disebut "support vectors" [4].



Gambar 1. Support vectors [4]

2.2 Kernel Function

Kernel function adalah metode yang digunakan untuk mengambil data sebagai input dan mengubahnya menjadi bentuk yang diperlukan untuk memproses data [5]. "Kernel" digunakan karena serangkaian fungsi matematika yang digunakan dalam Mesin Vektor Pendukung memberikan kesempatan untuk memanipulasi data. Jadi, kernel function pada umumnya mengubah set data latih sehingga permukaan keputusan non-linear dapat diubah menjadi persamaan linear dalam ruang dimensi yang lebih tinggi. Pada dasarnya, Kernel function mengembalikan hasil perkalian dalam dua titik dalam dimensi fitur standar. Adapun rumus standar dari kernel function [5]:

$$K(\underline{x}) = 1, \text{ if } \|\underline{x}\| \leq 1 \quad (1)$$

$$K(\underline{x}) = 0, \text{ Otherwise} \quad (2)$$

Terdapat beberapa kernel function yang umum digunakan dalam pengklasifikasian yaitu, kernel linear, RBF, dan polynominal. Berikut ini adalah persamaan dari ketiga function kernel:

Rumus perhitungan dari kernel linear [3].

$$K(x, x_i) = x \cdot x_i \quad (3)$$

Rumus perhitungan dari kernel RBF [3].

$$K(x, x_i) = \exp(-\gamma * \|x - x_i\|^2) \quad (4)$$

Rumus perhitungan dari kernel polynomial [3].

$$K(x, x_i) = [y * (x, x_i) + coed]^d \quad (5)$$

2.3 Data

Dataset yang digunakan merupakan data sekunder yang diperoleh dari situs web <https://www.kaggle.com> yang dikenal sebagai "GTZAN dataset – Music Genre Clasification". Terdapat 10 genre musik yang diklasifikasikan yaitu, blues, classical, country, disco, hiphop, jazz, metal, pop, reggae, dan rock. Jumlah dari masing – masing genre adalah sebanyak 100 data untuk setiap genre musik dengan format WAV. Dalam dataset juga terdapat file CSV "features_3_sec.csv" yang berisi hasil ekstraksi fitur dari setiap audio musik, data tersebut adalah data yang digunakan dalam penelitian ini.

```
Index(['length', 'chroma_stft_mean', 'chroma_stft_var', 'rms_mean', 'rms_var',  
      'spectral_centroid_mean', 'spectral_centroid_var',  
      'spectral_bandwidth_mean', 'spectral_bandwidth_var', 'rolloff_mean',  
      'rolloff_var', 'zero_crossing_rate_mean', 'zero_crossing_rate_var',  
      'harmony_mean', 'harmony_var', 'perceptr_mean', 'perceptr_var', 'tempo',  
      'mfcc1_mean', 'mfcc1_var', 'mfcc2_mean', 'mfcc2_var', 'mfcc3_mean',  
      'mfcc3_var', 'mfcc4_mean', 'mfcc4_var', 'mfcc5_mean', 'mfcc5_var',  
      'mfcc6_mean', 'mfcc6_var', 'mfcc7_mean', 'mfcc7_var', 'mfcc8_mean',  
      'mfcc8_var', 'mfcc9_mean', 'mfcc9_var', 'mfcc10_mean', 'mfcc10_var',  
      'mfcc11_mean', 'mfcc11_var', 'mfcc12_mean', 'mfcc12_var', 'mfcc13_mean',  
      'mfcc13_var', 'mfcc14_mean', 'mfcc14_var', 'mfcc15_mean', 'mfcc15_var',  
      'mfcc16_mean', 'mfcc16_var', 'mfcc17_mean', 'mfcc17_var', 'mfcc18_mean',  
      'mfcc18_var', 'mfcc19_mean', 'mfcc19_var', 'mfcc20_mean', 'mfcc20_var',  
      'label'],  
      dtype='object')
```

Gambar 3. Data Frame File CSV

2.4 Normalisasi Fitur

Proses ini terdiri dari dua langkah utama yaitu normalisasi fitur dan pembagian data menjadi set pelatihan, validasi, dan pengujian. Langkah pertama adalah normalisasi fitur, langkah ini dilakukan dengan menggunakan "StandardScaler" dari "sklearn.preprocessing". Fungsi dari "StandardScaler" adalah menghitung rata-rata dan standar deviasi dari setiap fitur "x" dan mentransformasikannya sehingga setiap fitur memiliki rata-rata nol dan varians satu. Hasil dari normalisasi akan disimpan dalam "x_scaled". Langkah kedua adalah pembagian data menjadi beberapa subset untuk pelatihan, validasi, dan pengujian. Pembagian ini dilakukan dalam dua tahap menggunakan "train_test_split" dari pustaka "sklearn.model_selection". Pada tahap pertama data dibagi menjadi dua bagian yaitu 70% untuk data pelatihan dan validasi ("X_train_val" dan "y_train_val") dan 30% untuk data pengujian awal ("X_test_initial" dan "y_test_initial"). Lalu pada tahap kedua, data pengujian awal dibagi menjadi dua bagian yaitu 50% untuk validasi ("X_val" dan "y_val") dan 50% untuk pengujian akhir ("X_test_final" dan "y_test_final").

2.5 Pelatihan Model SVM

Pelatihan model SVM dalam penelitian ini dimulai dengan inisialisasi model SVM untuk setiap kernel yang didefinisikan dalam daftar "kernels", yaitu "linear", "poly", dan "rbf". Pada setiap iterasi dalam loop "for", model SVM diinisialisasi dengan kernel spesifik menggunakan "SVC(kernel=kernel)". Setelah model diinisialisasi, model akan dilatih dengan menggunakan metode "fit" pada data pelatihan "X_train" dan labelnya "y_train". Proses pelatihan ini melibatkan penyesuaian parameter model untuk memaksimalkan kinerja pada data pelatihan sehingga model dapat memisahkan atau mengklasifikasikan data dengan baik berdasarkan kernel yang digunakan. Selanjutnya, dilakukan tuning hyperparameter untuk masing-masing kernel menggunakan Grid Search. Parameter grid didefinisikan dalam dictionary "param_grid" mencakup berbagai nilai untuk hyperparameter "c" pada semua kernel, serta "degree" untuk kernel polinomial dan "gamma" untuk kernel rbf. Grid Search dilakukan dengan "GridSearchCV", yang melibatkan pelatihan model dengan setiap kombinasi hyperparameter yang mungkin dan mengevaluasi kinerjanya menggunakan cross-validation dengan 5 lipatan ("cv=5"). Kombinasi hyperparameter terbaik dipilih berdasarkan akurasi tertinggi pada data validasi.

2.6 Evaluasi

Proses evaluasi model SVM dilakukan setelah melalui tahap pelatihan dan tuning hyperparameter. Evaluasi dimulai dengan menggunakan model terbaik yang ditemukan melalui Grid Search untuk masing-masing kernel: linear, polinomial (poly), dan Radial Basis Function (rbf). Setelah model terbaik dipilih, evaluasi dimulai dengan menggunakan data validasi ("X_val" dan "y_val"). Model SVM digunakan untuk membuat prediksi pada data validasi, dan hasil prediksi ini dibandingkan dengan label sebenarnya ("y_val"). Metrik evaluasi yang digunakan dalam kode tersebut adalah akurasi, yang mengukur persentase prediksi yang benar dari total prediksi yang dibuat. Hasil akurasi dari prediksi pada data validasi kemudian dicatat untuk setiap kernel dan disimpan dalam sebuah dictionary "best_model_accuracies". Dengan mengevaluasi model menggunakan data validasi yang tidak digunakan selama proses pelatihan atau tuning hyperparameter, kita dapat menilai secara obyektif kinerja model yang dihasilkan. Evaluasi ini memungkinkan kita untuk membandingkan kinerja berbagai kernel SVM setelah tuning hyperparameter dan memilih kernel yang memberikan hasil terbaik untuk tugas klasifikasi yang diberikan.

3. Hasil dan Diskusi

Tabel 1. Nilai Akurasi

Kernel	Persentase
linear	77.30%

Kernel	Persentase
polynomial	79.77%
RBF	85.25%

Tabel diatas adalah nilai akurasi sebelum dilakukannya tuning hyperparameter. Nilai akurasi yang diperoleh untuk masing-masing kernel SVM memberikan gambaran awal tentang kinerja model dengan menggunakan parameter default. Akurasi untuk kernel linear tercatat sebesar 77.30%, menunjukkan bahwa model ini mampu mengklasifikasikan data dengan tingkat akurasi yang cukup baik tanpa penyetelan lebih lanjut. Kernel polynomial menghasilkan akurasi sebesar 79.77%, yang sedikit lebih tinggi dibandingkan kernel linear, menunjukkan bahwa kernel ini bisa menangkap beberapa pola non-linear dalam data dengan lebih efektif. Kernel RBF mencatat akurasi tertinggi sebesar 85.25%, menunjukkan keunggulannya dalam menangani data yang mungkin memiliki pola yang lebih kompleks dan non-linear.

3.1. Hasil Akurasi

Tabel 2. Nilai Akurasi Tuning Hyperparameter

Kernel	Persentase
linear	76.84%
polynomial	88.92%
RBF	89.32%

Tabel diatas ini merupakan hasil nilai akurasi setelah tuning hyperparameter menggunakan Grid Search, hasil nilai akurasi menunjukkan perubahan yang signifikan dibandingkan dengan akurasi sebelum tuning. Akurasi untuk kernel linear sedikit menurun dari 77.30% menjadi 76.84%, yang mungkin disebabkan oleh overfitting atau perubahan parameter yang tidak cocok untuk data ini. Namun, kernel polynomial dan RBF menunjukkan peningkatan akurasi yang substansial. Akurasi kernel polynomial meningkat dari 79.77% menjadi 88.92%, dan akurasi kernel RBF meningkat dari 85.25% menjadi 89.32%. Peningkatan akurasi pada kernel polynomial dan RBF menunjukkan bahwa tuning hyperparameter berhasil menemukan kombinasi parameter yang lebih optimal untuk model, sehingga model dapat lebih baik dalam mengklasifikasikan data pada set validasi.

4. Kesimpulan

Berdasarkan hasil pengujian, klasifikasi genre musik menggunakan metode Support Vector Machine (SVM) dengan multi-kernel menunjukkan kinerja yang sangat baik. Dengan menggunakan dataset GTZAN yang terdiri dari 10 genre musik dan ekstraksi fitur audio, model SVM berhasil mencapai akurasi yang signifikan pada data pengujian. Sebelum tuning hyperparameter, akurasi terbaik yang dicapai oleh kernel RBF adalah sebesar 85.25%. Setelah tuning hyperparameter, terjadi peningkatan akurasi yang substansial, terutama pada kernel polynomial dan RBF. Kernel polynomial meningkat dari 79.77% menjadi 88.92%, dan kernel RBF meningkat dari 85.25% menjadi 89.32%, menunjukkan bahwa tuning hyperparameter berhasil menemukan kombinasi parameter yang lebih optimal untuk model, sehingga model dapat lebih baik dalam mengklasifikasikan data pada set validasi.

Daftar Pustaka

- [1] F.Aulia, "Keberagaman Genre Musik yang Bisa Memecah Belah Penikmatnya", 28 April 2024. [Online]. Available: <https://geotimes.id/komentar/keberagaman-genre-musik-yang-bisa-memecah-belah-penikmatnya/>. [8 Mei 2024]

- [2] Ardiansyah, and Meilina. "Klasifikasi Genre Musik Menggunakan Metode Support Vector Machine." *Jurnal Ilmiah Fasilkom* 5, no. 2, 81–86, 2016
- [3] Ren, Yili, Fuxiang Hu and Hongping Miao. "The optimization of kernel function and its parameters for SVM in well-logging." 2016 13th International Conference on Service Systems and Service Management (ICSSSM), 1-5, 2016
- [4] BINUS. "Support Vector Machine Algorithm", 14 Februari 2022. [Online]. Available: <https://sis.binus.ac.id/2022/02/14/support-vector-machine-algorithm/>. [7 Mei 2024]
- [5] N.Fury. "Major Kernel Function in Support Vector Machine (SVM)", 7 Februari 2022. [Online]. Available: <https://www.geeksforgeeks.org/major-kernel-functions-in-support-vector-machine-svm/>. [7 Mei 2024]
- [6] G. A. V. M. Giri and M. L. Radhitya, "Klasifikasi Genre Musik Menggunakan Teknik Pembelajaran Mesin", *Jutik*, vol. 9, no. 1, 2023.
- [7] Jaya, E., Santosa. "Klasifikasi Genre Musik Menggunakan Metode Support Vector Machine". *Jurnal Ilmiah Fasilkom* 81–82, 2016