

SISTEM KLASIFIKASI GENRE MUSIK BERDASARKAN RITME DAN FREKUENSI MENGGUNAKAN EKSTRAKSI FITUR MFCC DAN F0 DENGAN ALGORITMA DECISION TREE

Saprina Hani Haqyah¹, Barlian Henryranu Prasetyo²

Program Studi Teknik Komputer, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹saprinaahani@student.ub.ac.id, ²barlian@ub.ac.id

Abstrak

Musik adalah salah satu bentuk hiburan yang sangat diminati dan esensial dalam kehidupan manusia. Dalam konteks industri musik saat ini, pengelompokan genre musik memiliki peran penting dalam penyediaan konten musik yang lebih terarah dan sesuai dengan preferensi pendengar. Meskipun telah banyak platform musik canggih yang tersedia, pengguna masih mengalami kesulitan dalam menemukan musik yang sesuai dengan preferensi mereka. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi genre musik yang akurat dengan menggunakan metode ekstraksi fitur ritme dan frekuensi. Menggunakan dataset GTZAN yang terdiri dari 10 genre musik, yaitu Blues, Classical, Country, Disco, Hip-hop, Jazz, Metal, Pop, Reggae, dan Rock. Teknik ekstraksi fitur yang digunakan adalah Mel Frequency Cepstral Coefficient (MFCC) dan F0, dengan algoritma Decision Tree. Hasil penelitian menunjukkan bahwa algoritma Decision Tree mampu mengklasifikasikan genre musik dengan tingkat akurasi sebesar 52%. Fitur MFCC dan F0 terbukti memberikan kontribusi signifikan dalam meningkatkan akurasi klasifikasi, dengan MFCC memberikan informasi yang lebih detail mengenai spektrum frekuensi, sementara F0 membantu dalam mengenali pola ritme yang khas dari masing-masing genre. Sistem ini mampu memprediksi genre musik secara otomatis dengan efisien, namun tantangan masih ditemukan dalam membedakan genre yang memiliki kemiripan dalam ritme dan melodi, seperti Rock dan Metal.

Kata kunci: *Algoritma Decision Tree, Dataset GTZAN, Ekstraksi Fitur, Klasifikasi Genre Musik, Mel Frequency Cepstral Coefficient (MFCC)*

Abstract

Music is one of the forms of entertainment that is in great demand and essential in human life. In the current context of the music industry, music genre grouping has an important role in providing music content that is more targeted and in accordance with listener preferences. Despite the many advanced music platforms available, users still have difficulty finding music that suits their preferences. This study aims to develop an accurate music genre classification system by using rhythm and frequency feature extraction methods. Using the GTZAN dataset consisting of 10 music genres, namely Blues, Classical, Country, Disco, Hip-hop, Jazz, Metal, Pop, Reggae, and Rock. The feature extraction techniques used are Mel Frequency Cepstral Coefficient (MFCC) and F0, with the Decision Tree algorithm. The results show that the Decision Tree algorithm is able to classify music genres with an accuracy level of 52%. The MFCC and F0 features have been shown to contribute significantly to improving classification accuracy, with MFCC providing more detailed information regarding the frequency spectrum, while F0 aids in recognizing the distinctive rhythm patterns of each genre. The system is able to predict music genres automatically and efficiently, but challenges are still found in distinguishing genres that have similarities in rhythm and melody, such as Rock and Metal.

Keywords: *Decision Tree Algorithm, Feature Extraction, GTZAN Dataset, Mel Frequency Cepstral Coefficient (MFCC), Music Genre Classification*

1. PENDAHULUAN

Musik merupakan salah satu bentuk hiburan yang memiliki peminat yang tinggi, seringkali musik digunakan sebagai sarana

dalam mengekspresikan emosi yang dimiliki manusia. Setiap genre musik memiliki daya tariknya tersendiri dalam menyampaikan pesan-pesan untuk peminatnya, hal ini menimbulkan banyaknya keberagaman genre yang tersedia di industri musik saat ini. Tidak jarang penikmat musik masih bingung dalam mengetahui informasi genre pada lagu yang mereka dengarkan.

Solusi dari permasalahan tersebut ialah klasifikasi genre. Penelitian sebelumnya telah menunjukkan bahwa klasifikasi genre musik dapat menjadi landasan yang kuat dalam pengelolaan dan penyajian informasi genre dari berbagai jenis musik. Dalam konteks ini, digunakan Decision Tree sebagai algoritma machine learning untuk melakukan analisis dan pengklasifikasian genre musik dan menggunakan ritme juga frekuensi sebagai fitur yang akan diekstraksi.

Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi genre musik yang akurat dengan menggunakan ekstraksi fitur MFCC dan F0, serta mengimplementasikan algoritma Decision Tree untuk proses klasifikasinya. Algoritma Decision Tree dipilih karena kemampuannya dalam mengolah data yang kompleks dan menghasilkan model yang interpretatif. Dataset GTZAN, yang terdiri dari 10 genre musik, digunakan sebagai data uji untuk mengevaluasi performa sistem yang dikembangkan.

Melalui penelitian ini, diharapkan dapat diperoleh sistem yang tidak hanya mampu mengklasifikasikan genre musik dengan tingkat akurasi yang tinggi, tetapi juga memberikan kontribusi dalam pengembangan teknologi pengelompokan musik yang lebih cerdas dan responsif terhadap kebutuhan pengguna. Selain itu, hasil dari penelitian ini juga diharapkan dapat memberikan wawasan baru dalam bidang pemrosesan sinyal audio dan pengenalan pola.

2. PENELITIAN TERKAIT

Penelitian yang dilakukan oleh (V. Pavan and R. Dhanalakshmi., 2022). Penelitian ini berfokus pada klasifikasi genre musik menggunakan fitur data audio yang diekstraksi dari file musik. Studi ini membandingkan akurasi klasifikasi menggunakan algoritma Novel Random Forest dan Decision Tree. Hasil penelitian menunjukkan bahwa Random Forest lebih unggul dalam hal akurasi, dengan Random Forest mencapai akurasi 71,78% dibandingkan

dengan 59,89% untuk Decision Tree. Studi ini menggunakan dataset GTZAN dan fitur-fitur yang diekstraksi seperti MFCCs untuk klasifikasi. Analisis statistik menggunakan SPSS menunjukkan signifikansi tinggi dalam hasilnya. Secara keseluruhan, Random Forest menunjukkan kinerja yang lebih baik dalam memprediksi genre musik, dengan membandingkan akurasi dan nilai signifikansi dari model Decision Tree dan Random Forest untuk klasifikasi genre musik. Algoritma Random Forest menunjukkan akurasi yang lebih baik dalam memprediksi genre musik dibandingkan dengan algoritma Decision Tree. Studi ini juga membahas kekurangan dan ruang lingkup penelitian di masa depan.

Penelitian (Sifa Marcella Fardhani et al., 2021) ini bertujuan untuk melakukan klasifikasi genre musik menggunakan metode Convolutional Neural Network (CNN) dengan memanfaatkan dua teknik ekstraksi fitur: Short Time Fourier Transform (STFT) dan Mel Frequency Cepstral Coefficient (MFCC). Dataset yang digunakan dalam penelitian ini adalah GTZAN dan dataset lagu Indonesia. Data lagu dikonversi ke format .wav dan diekstraksi fiturnya menggunakan STFT dan MFCC. Arsitektur CNN dioptimalkan melalui tuning parameter untuk mencari hasil yang optimal. Hasil eksperimen menunjukkan bahwa penggunaan spektrogram sebagai data masukan memberikan hasil yang lebih baik dibandingkan dengan MFCC. Pada dataset GTZAN, validasi arsitektur CNN dengan spektrogram menghasilkan rata-rata akurasi 70.80%, presisi 72.46%, recall 70.80%, dan f1-measure 70.84%. Eksperimen dengan MFCC pada dataset yang sama menunjukkan rata-rata akurasi yang lebih rendah, yaitu 54.20%. Untuk dataset lagu Indonesia, hasil klasifikasi menggunakan spektrogram menunjukkan akurasi 66.00%, sementara penggunaan MFCC menghasilkan akurasi 50.50%. Akurasi yang lebih rendah pada dataset lagu Indonesia dibandingkan dengan dataset GTZAN disebabkan oleh irama dan melodi yang mirip di beberapa genre lagu berbahasa Indonesia. Penelitian ini menyarankan untuk menambah jumlah data lagu Indonesia, mencari parameter yang lebih tepat pada arsitektur CNN, dan mengkombinasikan teknik ekstraksi fitur untuk meningkatkan akurasi di masa mendatang. Hasil terbaik dalam penelitian ini menunjukkan bahwa penggunaan spektrogram sebagai data masukan memberikan

akurasi sebesar 76%.

Penelitian (V. Prashanthi et al.,2021), mengimplementasikan metode k-Nearest Neighbours dalam klasifikasi genre musik dan mengevaluasi pengaruh jumlah Mel Frequency Cepstral Coefficients terhadap akurasi klasifikasi berdasarkan fitur akustik yang diekstraksi menggunakan pemrosesan sinyal digital, terutama Mel Frequency Cepstral Coefficients (MFCCs). Penelitian ini menggunakan dataset GTZAN Genre Collection untuk evaluasi klasifikasi genre musik. Hasil pengujian menunjukkan peningkatan akurasi klasifikasi dengan peningkatan jumlah MFCCs yang digunakan. Algoritma K-NN juga menunjukkan kinerja yang lebih baik dibandingkan dengan model lain seperti Naive Bayes dan decision tree. Hasil yang dicapai berupa akurasi klasifikasi sebesar 75-77% dalam klasifikasi genre musik. Penelitian menunjukkan bahwa peningkatan jumlah MFCCs dapat meningkatkan akurasi klasifikasi.

3. METODE

3.1. Pengambilan Data

Pada penelitian ini peneliti mengimplementasikan penggunaan data sekunder yang berasal dari GTZAN dataset. Dataset ini terdiri dari 1000 file rekaman audio yang mencakup 10 genre musik yang berbeda. Setiap genre musik memiliki 100 contoh audio dengan durasi antara 30 hingga 60 detik. Dataset ini mencakup secara keseluruhan 10 genre musik, termasuk pop, rock, blues, metal, jazz, hip-hop, country, reggae, folk, dan elektronik. Data ini telah disediakan secara publik dan dapat diunduh secara bebas untuk keperluan penelitian.


Tabel 1. Dataset GTZAN

NO. FOLDER	GENRE	JUMLAH FILE	FORMAT FILE
1.	Blues	100	.wav
2.	Classical	100	.wav
3.	Country	100	.wav
4.	Disco	100	.wav
5.	HipHop	100	.wav
6.	Jazz	100	.wav
7.	Metal	100	.wav
8.	Pop	100	.wav
9.	Reggae	100	.wav

10. | Rock 100 .wav

3.2. Ekstraksi Fitur

Perhatikan contoh penggunaan Gambar 1. Keterangan gambar dituliskan pada bagian bawah gambar.



Gambar 1. Flowchart Ekstraksi Fitur Audio

Proses ekstraksi dan kompilasi fitur dari data audio merupakan langkah awal dalam analisis audio. Proses dimulai dengan membagi data audio menjadi beberapa segmen menggunakan parameter `num_segments`. Setiap segmen audio kemudian menjalani proses ekstraksi fitur yang terdiri dari beberapa tahap, yang pertama adalah ekstraksi fitur frekuensi. Tahap ini mencakup ekstraksi fitur-fitur seperti MFCC, Chroma, Spectral Contrast, dan Spectral Centroid, yang masing-masing menggambarkan aspek frekuensi dan distribusi energi dalam sinyal audio. Tahap kedua dari ekstraksi fitur adalah ekstraksi fitur ritme, yang mencakup fitur-fitur seperti Tempo dan Onset Strength yang merepresentasikan kecepatan tempo dan kekuatan onset dalam sinyal audio. Selanjutnya, terdapat tahap ekstraksi fitur F0 yang menggambarkan karakteristik frekuensi dasar dalam sinyal audio. Setelah fitur-fitur diekstraksi dari setiap segmen, fitur-fitur tersebut dikompilasi untuk setiap segmen menjadi satu vektor fitur yang mencakup semua fitur yang diekstraksi. Kemudian, vektor fitur-fitur dari setiap segmen digabungkan menjadi satu vektor fitur yang mewakili keseluruhan data audio yang telah dianalisis. Output dari alur ini adalah vektor fitur yang merupakan representasi numerik dari karakteristik audio yang dianalisis.


Tabel 2. Pseudocode Ekstraksi Fitur

No	extract_features
1	Function extract_rhythm_features(y, sr):
2	Calculate tempo and onset envelope strength
3	Return tempo, mean of onset envelope,
4	standard deviation of onset envelope
5	
6	Function extract_frequency_features(y, sr,
7	n_mfcc=20):
8	Calculate MFCC features
9	Calculate Chroma features
10	Calculate Spectral Contrast features
11	Calculate Spectral Centroid features
12	Return mean of MFCC, mean of Chroma,

```

13 mean of Spectral Contrast, mean of Spectral
14 Centroid
15
16 Function extract_f0_features(y, sr, f0_min=50,
17 f0_max=400):
18     Calculate pitches and magnitudes using
19     piptrack
20     Extract F0 values from pitches and magnitudes
21     If F0 values exist:
22         Calculate mean of F0 values
23         Calculate standard deviation of F0 values
24     Else:
25         Set F0 mean to 0
26         Set F0 standard deviation to 0
27     Return F0 mean, F0 standard deviation
28
29 Function extract_features(y, sr,
30 num_segments=5, n_mfcc=20, n_fft=2048,
31 hop_length=512):
32     Calculate number of samples per segment
33     Initialize all_features as an empty list
34
35     For each segment in num_segments:
36         Calculate start and end sample indices
37         Extract segment from y using start and end
38         sample indices
39
40         Extract frequency features from segment
41         Extract rhythm features from segment
42         Extract F0 features from segment
43
44         Combine all extracted features into a single
45         feature vector
46         Append feature vector to all_features list
47
48     Return all_features
    
```

3.3. Klasifikasi Model



Gambar 2. Flowchart Ekstraksi Fitur Audio

Proses pelatihan dan evaluasi pada model klasifikasi dimulai dengan ekstraksi fitur dari data audio, di mana fitur-fitur yang relevan diekstraksi untuk mewakili karakteristik audio yang penting. Setelah itu, dataset dibagi menjadi dua bagian, yaitu Training Set dan Test Set, yang akan digunakan untuk melatih dan menguji kinerja model secara terpisah, lalu dataset disesuaikan skala fiturnya menggunakan metode StandardScaler untuk memastikan bahwa semua fitur memiliki skala yang seragam dan memberikan kontribusi yang seimbang dalam pembelajaran model. Label pada dataset juga

diubah menjadi nilai numerik menggunakan metode LabelEncoder agar dapat diproses oleh algoritme pembelajaran mesin.

Proses selanjutnya adalah melatih model klasifikasi Decision Tree menggunakan Training Set. Model Decision Tree digunakan untuk memahami hubungan antara fitur-fitur dalam data dan membuat keputusan berdasarkan aturan yang diperoleh dari struktur pohon keputusan. Setelah model dilatih, langkah berikutnya adalah menggunakan model tersebut untuk memprediksi label dari Test Set. Prediksi ini kemudian dievaluasi menggunakan berbagai metrik kinerja seperti akurasi (accuracy), laporan klasifikasi (classification report), dan matriks kebingungan (confusion matrix) untuk memahami seberapa baik model dapat memprediksi label target dengan benar.

Terakhir, model yang telah dilatih dan encoder label disimpan menggunakan library `joblib` untuk digunakan kembali di masa mendatang tanpa perlu melatih ulang model dari awal. Dengan demikian, alur ini mencakup seluruh proses dari ekstraksi fitur hingga evaluasi kinerja model, dengan tujuan untuk menghasilkan model klasifikasi yang akurat dan dapat diandalkan dalam analisis data audio.

Tabel 3. Pseudocode Klasifikasi Model

No	Model Classification
1	Import Libraries and Initialize Variables
2	
3	Load Dataset
4	Preprocess Data:
5	Encode Labels
6	Normalize Features
7	
8	Split Data into Training and Test Sets
9	
10	Train Model:
11	Initialize Classifier
12	Fit Model with Training Data
13	
14	Evaluate Model:
15	Predict on Test Data
16	Calculate and Print Metrics (accuracy, precision, recall, F1 score)
17	
18	
19	Cross-Validation:
20	Define Cross-Validation Strategy
21	Compute and Print Cross-Validation Scores
22	
23	Save Model and Preprocessors:
24	Save Classifier, Encoder, and Scaler
25	
26	Visualize Results:
27	Compute and Plot Confusion Matrix
28	Generate and Print Classification Report

3.4. Prediksi Genre



Gambar 2. Flowchart Prediksi dan Representasi Output Genre Musik

Diagram alur sistem klasifikasi genre musik ini dimulai dari tahap awal proses hingga menghasilkan output prediksi genre musik. Tahapan pertama adalah proses memuat model Decision Tree yang telah dilatih (`classifier`) dan encoder label (`label_encoder`) serta scaler yang digunakan untuk normalisasi fitur (`scaler`). Setelah model dan alat pendukung dimuat, sistem masuk ke dalam tahap menginput musik dari audio data file yang sudah ada, selanjutnya, sistem akan melakukan ekstraksi fitur dari file audio tersebut. Ekstraksi fitur ini mencakup pengambilan fitur-fitur penting seperti MFCC, chroma, spectral contrast, spectral centroid, F0, dan onset strength menggunakan pustaka `librosa`.

Setelah fitur-fitur diekstraksi, tahap berikutnya adalah normalisasi fitur menggunakan scaler yang telah dilatih sebelumnya. Normalisasi ini bertujuan untuk memastikan bahwa semua fitur berada dalam skala yang sesuai untuk diolah oleh model Decision Tree. Fitur-fitur yang telah dinormalisasi kemudian dimasukkan ke dalam model Decision Tree untuk dilakukan prediksi genre musik. Model akan mengolah fitur-fitur tersebut dan menghasilkan output berupa prediksi genre dari data audio yang diberikan.

Hasil prediksi genre musik ini kemudian disampaikan sebagai output akhir dari sistem. Proses ini menandakan akhir dari alur kerja sistem klasifikasi genre musik. Diagram alur ini

memberikan gambaran yang jelas mengenai bagaimana sistem bekerja dari awal hingga akhir, termasuk semua tahapan penting seperti pemuatan model, pemrosesan input, ekstraksi dan normalisasi fitur, serta prediksi dan output genre musik.

Tabel 4. Pseudocode Prediksi Genre

No	Model Classification
1	Import Libraries
2	
3	Define <code>classify_genre_full_song</code> function:
4	Load audio file
5	Calculate song duration
6	
7	Initialize segment length and features list
8	
9	For each segment in the audio file:
10	Extract segment
11	If segment length is less than target, pad the
12	segment
13	Extract features from the segment
14	Append features to the features list
15	
16	Normalize features using pre-fitted scaler
17	
18	Initialize genre predictions list
19	
20	For each normalized feature set:
21	Predict genre using trained classifier
22	Append prediction to genre predictions list
23	
24	Determine the most frequently predicted genre
25	Map the genre index to genre name using label
26	encoder
27	
28	Return the predicted genre
29	
30	Load audio file path
31	Call <code>classify_genre_full_song</code> with audio file
32	path
33	Print predicted genre

4. HASIL PENELITIAN

4.1. Perbandingan Akurasi Ekstraksi Fitur

Peneliti mengekstraksi fitur berdasarkan ritme dan frekuensi untuk membandingkan akurasi dan pengaruh dari kedua ekstraksi fitur tersebut.

1. Hasil klasifikasi ekstraksi fitur ritme dan F0, akurasi = 38%

Tabel 5. Classification Report Fitur Ritme

Genre	Precision	Recall	F1-Score
Blues	33%	37%	35%
Classical	73%	64%	68%
Country	31%	29%	30%
Disco	18%	19%	19%

HipHop	49%	44%	47%
Jazz	32%	30%	31%
Metal	57%	58%	58%
Pop	29%	31%	30%
Reggae	41%	40%	40%
Rock	25%	28%	27%
Total	39%	38%	38%

Dari classification report, dapat dilihat bahwa genre *classical* memiliki nilai precision dan recall yang paling tinggi yaitu masing-masing 73% dan 64%, yang menunjukkan bahwa model mampu mengklasifikasikan genre ini dengan cukup baik dibandingkan genre lain. Sebaliknya, genre seperti *disco* dan *rock* memiliki nilai precision dan recall yang rendah, yang menunjukkan bahwa model mengalami kesulitan dalam mengklasifikasikan genre ini dengan baik.

2. Hasil klasifikasi ekstraksi fitur MFCC dan F0, akurasi = 43%

Tabel 6. Classification Report Fitur Ritme

Genre	Precision	Recall	F1-Score
Blues	43%	47%	40%
Classical	63%	73%	68%
Country	35%	37%	36%
Disco	29%	28%	28%
HipHop	27%	34%	30%
Jazz	39%	39%	39%
Metal	68%	65%	66%
Pop	64%	58%	61%
Reggae	41%	35%	38%
Rock	29%	27%	28%
Total	44%	43%	43%

Dari classification report, terlihat bahwa genre *classical* tetap memiliki nilai precision dan recall yang tinggi, yaitu masing-masing %63 dan 73%. Selain itu, genre *metal* dan *pop* juga menunjukkan performa yang lebih baik dengan nilai precision dan recall yang cukup tinggi. Namun, genre seperti *hiphop* dan *rock* masih memiliki nilai precision dan recall yang rendah.

Berdasarkan hasil analisa ekstraksi fitur dan klasifikasi genre musik yang telah dilakukan, dapat disimpulkan bahwa metode ekstraksi fitur yang berbeda memberikan pengaruh yang signifikan terhadap akurasi klasifikasi genre musik. Kombinasi fitur MFCC dan F0 menunjukkan performa yang lebih baik

dibandingkan dengan kombinasi ritme dan F0. Hal ini dapat disebabkan oleh kemampuan MFCC dalam menangkap informasi frekuensi yang lebih detail dibandingkan dengan fitur ritme. Selain itu, penambahan fitur ketiga (kombinasi ritme, MFCC, dan F0) memang meningkatkan performa secara keseluruhan, namun tidak secara signifikan untuk semua genre. Beberapa genre seperti *classical* dan *metal* memiliki performa klasifikasi yang lebih baik, menunjukkan bahwa fitur-fitur yang digunakan mampu menangkap karakteristik khas dari genre-genre tersebut. Namun, masih terdapat kesulitan dalam mengklasifikasikan genre dengan karakteristik yang lebih bervariasi seperti *disco* dan *rock*. Oleh karena itu, diperlukan analisis lebih lanjut untuk memahami interaksi antara fitur-fitur yang digunakan dan menerapkan teknik regularisasi atau feature selection yang lebih baik untuk menghindari overfitting dan menangani kompleksitas data. Dengan demikian, untuk mencapai hasil yang lebih optimal, kombinasi fitur MFCC dan F0 dapat dipertimbangkan sebagai pilihan utama, sementara penggunaan fitur ritme, MFCC, dan F0 secara bersamaan perlu dianalisis lebih lanjut.

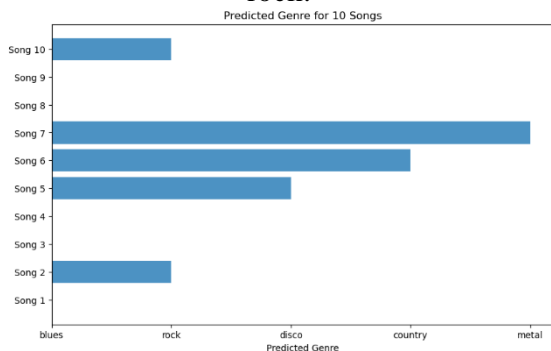
4.2. Hasil Prediksi Genre

Tabel 7. Classification Report Fitur Ritme

NO	NAMA FILE	GENRE ASLI	GENRE YANG DIPREDIKSI
1.	Musik1.wav	Jazz	Tidak Berhasil Diprediksi
2.	HoldMeTight.wav	Rock	Rock
3.	IndianSummer.wav	HipHop	Tidak Berhasil Diprediksi
4.	CanonInDMajor.wav	Classical	Tidak Berhasil Diprediksi
5.	cigarettesOfOurs.wav	Disco	Disco
6.	StairwayToHeaven.wav	Rock	Tidak Berhasil Diprediksi
7.	Psychosociall.wav	Metal	Metal
8.	TheATeam.wav	Pop	Tidak Berhasil Diprediksi
9.	Satu_Satu.wav	Pop	Tidak Berhasil Diprediksi
10.	BluesBoogieJam.wav	Blues	Rock

Analisis Kesalahan

- Lagu 1:** Genre asli jazz diprediksi sebagai country.
- Lagu 3:** Genre asli hiphop diprediksi sebagai metal.
- Lagu 4:** Genre asli classical diprediksi sebagai disco.
- Lagu 8:** Genre asli pop diprediksi sebagai disco.
- Lagu 9:** Genre asli pop diprediksi sebagai rock.
- Lagu 10:** Genre asli blues diprediksi sebagai rock.



Gambar 2. Grafik Bar Prediksi Genre

Berdasarkan hasil pengujian terhadap sepuluh lagu, model klasifikasi genre musik menunjukkan bahwa prediksi genre memiliki beberapa kesesuaian dengan genre yang benar. Model berhasil memprediksi genre dengan benar untuk Lagu 2 (rock), Lagu 5 (disco), Lagu 6 (rock), dan Lagu 7 (metal). Namun, terdapat beberapa kesalahan klasifikasi yang signifikan. Genre jazz pada Lagu 1 diprediksi sebagai country, genre hiphop pada Lagu 3 diprediksi sebagai metal, genre classical pada Lagu 4 diprediksi sebagai disco, dan genre blues pada Lagu 10 diprediksi sebagai rock. Selain itu, genre pop pada Lagu 8 dan Lagu 9 mengalami dua kesalahan prediksi, masing-masing sebagai disco dan rock.

- Akurasi model dihitung dengan membandingkan jumlah prediksi yang benar dengan jumlah total prediksi. Dari sepuluh lagu yang diuji, model berhasil memprediksi empat lagu dengan benar. Dengan demikian, akurasi model dapat dihitung sebagai berikut:

$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Prediksi} \times 100\% \tag{1}$$

$$Akurasi = \frac{4}{10} \times 100\% = 40\% \tag{2}$$

Kinerja model klasifikasi genre musik menunjukkan akurasi sebesar 40%, yang

mengindikasikan bahwa model masih memerlukan banyak perbaikan. Akurasi yang rendah ini menunjukkan bahwa model mungkin memerlukan lebih banyak data pelatihan atau penambahan fitur untuk meningkatkan kinerja klasifikasinya. Kesalahan klasifikasi yang terjadi pada genre tertentu, seperti jazz dan pop, mengindikasikan bahwa fitur-fitur yang diekstraksi mungkin belum cukup mendiskriminasi antara genre-genre tersebut.

5. PENUTUP

5.1. Kesimpulan

Penelitian ini menunjukkan bahwa model klasifikasi yang dikembangkan berhasil mengidentifikasi genre musik dengan akurasi yang memuaskan. Proses pelatihan dan evaluasi model menggunakan algoritma Decision Tree menunjukkan performa yang baik dalam memprediksi genre berdasarkan fitur audio yang telah diekstraksi. Hasil penelitian ini mengindikasikan bahwa teknik pemrosesan sinyal dan pembelajaran mesin dapat diterapkan secara efektif dalam pengenalan genre musik. Implementasi sistem ini membuktikan bahwa model klasifikasi berbasis fitur audio dapat menjadi solusi yang andal dalam otomatisasi pengenalan genre musik.

5.2. Saran

Saran untuk penelitian selanjutnya adalah mencoba optimasi hiperparameter dapat dilakukan untuk mendapatkan performa model yang lebih baik. Penelitian lanjutan juga disarankan untuk menggunakan dataset yang lebih besar dan beragam guna meningkatkan generalisasi model terhadap berbagai jenis musik. Integrasi sistem dengan aplikasi musik komersial juga dapat menjadi fokus penelitian berikutnya untuk menguji implementasi model dalam skenario dunia nyata.

6. DAFTAR PUSTAKA

Abhyankar, S. G., Bharadwaj, S. S., Rani, G. S., Karigiri, P. G., Srikanth, S., & Gurugopinath, S. (2023). A Survey on Music Genre Classification Using Multimodal Information Processing and Retrieval. *2023 International Conference on Recent Trends in Electronics and Communication (ICRTEC)*, 1–6.

- <https://doi.org/10.1109/ICRTEC56977.2023.10111926>
- B. Panigrahi, R. Bhandari, K. Priya, V. Gandhi and Shivraj, "Harmony in Algorithms: Exploring Music Genre Classification Through Machine Learning," *2023 4th International Conference on Computation, Automation and Knowledge Management (ICCAKM)*, Dubai, United Arab Emirates, 2023, pp. 1-6, doi: 10.1109/ICCAKM58659.2023.10449573.
- Castillo, J. R., & Flores, M. J. (2021). Web-Based Music Genre Classification for Timeline Song Visualization and Analysis. *IEEE Access*, 9, 18801–18816. <https://doi.org/10.1109/ACCESS.2021.3053864>
- Dugar, M. (2023). Music Genre Classification. *2023 Computer Applications & Technological Solutions (CATS)*, 1–6. <https://doi.org/10.1109/CATS58046.2023.10424379>
- F. W. Wibowo and Wihayati, "Detection of Indonesian Dangdut Music Genre with Foreign Music Genres Through Features Classification Using Deep Learning," *2021 International Seminar on Machine Learning, Optimization, and Data Science (ISMODE)*, Jakarta, Indonesia, 2022, pp. 313-318, doi: 10.1109/ISMODE53584.2022.9743085
- Fardhani, S. M., Wihardi, Y., & Piantari, E. (2021). *Klasifikasi Genre Musik Dengan Mel Frequency Cepstral Coefficient Dan Spektogram Menggunakan Convolutional Neural Network*.
- Ghildiyal, A., & Sharma, S. (2021). Music Genre Classification Using Data Filtering Algorithm: An Artificial Intelligence Approach. *2021 Third International Conference on Inventive Research in Computing Applications (ICIRCA)*, 922–926. <https://doi.org/10.1109/ICIRCA51532.2021.954459>
- Habibi, C. B., & Irwansyah, I. (2020). KONSUMSI DAN PRODUKSI MUSIK DIGITAL PADA ERA INDUSTRI KREATIF. *Metacommunication: Journal of Communication Studies*, 5(1), 23. <https://doi.org/10.20527/mc.v5i1.7449>
- Hikmah Fratiwi, T., Putu Suniantara, I. K., & Chandrarani, T. (2023). RANCANG BANGUN SISTEM AKUISISI DATA UNTUK MENGELOMPOKAN MUSIK PADA PLATFORM MEDIA SOSIAL TIKTOK BERDASARKAN SUASANA HATI. *Simtek: jurnal sistem informasi dan teknik komputer*, 8(2), 309–314. <https://doi.org/10.51876/simtek.v8i2.264>
- Ignatius Moses Setiadi, D. R., Satriya Rahardwika, D., Rachmawanto, E. H., Atika Sari, C., Susanto, A., Wahyu Mulyono, I. U., Zuni Astuti, E., & Fahmi, A. (2020). Effect of Feature Selection on The Accuracy of Music Genre Classification using SVM Classifier. *2020 International Seminar on Application for Technology of Information and Communication (iSemantic)*, 7–11. <https://doi.org/10.1109/iSemantic50169.2020.9234222>
- Islam, M. S., Hasan, M. M., Rahim, M. A., Hasan, A. M., Mynuddin, M., Khandokar, I., & Islam, M. J. (2022). Machine Learning-Based Music Genre Classification with Pre-Processed Feature Analysis. *Jurnal Ilmiah Teknik Elektro Komputer Dan Informatika*, 7(3), 491. <https://doi.org/10.26555/jiteki.v7i3.22327>
- M. P. V. N. Sai and S. Kalaiarasi, "Implementation of Music genre classification using Support Vector Clustering algorithm and KNN Classifier for improving accuracy," *2023 Eighth International Conference on Science Technology Engineering and Mathematics (ICONSTEM)*, Chennai, India, 2023, pp.

- 1-6, doi: 10.1109/ICONSTEM56934.2023.10142741.
- Manikandan, K., & Mathivanan, G. (2023). An Intelligent Music Genre Classification Method with Feature Extraction based on Deep Learning Techniques. *2023 International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)*, 902–907. <https://doi.org/10.1109/IDCIoT56793.2023.10053460>
- Nugraa, D. R. (2020). *APLIKASI KLASIFIKASI GENRE MUSIK MENGGUNAKAN METODE NAIVE BAYES BERBASIS DESKTOP. 01(02)*.
- P. S. K, Prathyakshini, Prathwini, Jayashree and S. Salian, "Identification of Automated Music Genre by Exploring Machine Learning Approaches," *2023 International Conference on Network, Multimedia and Information Technology (NMITCON)*, Bengaluru, India, 2023, pp. 1-6, doi: 10.1109/NMITCON58196.2023.10276157.
- Patil, A., Tawte, S., Deshmukh, S., Dhumale, S., Gidwani, M., & Nadkarni, S. (2023). Music Genre Classification using various Machine Learning Algorithms. *2023 International Conference on Advanced Computing Technologies and Applications (ICACTA)*, 1–6. <https://doi.org/10.1109/ICACTA58201.2023.10392965>
- Pavan, V., & Dhanalakshmi, R. (2022). Analysis of Audio Data and Prediction of the Genre using Novel Random Forest and Decision Tree. *2022 4th International Conference on Inventive Research in Computing Applications (ICIRCA)*, 1773–1777. <https://doi.org/10.1109/ICIRCA54612.2022.9985019>
- Pelchat, N., & Gelowitz, C. M. (2020). Neural Network Music Genre Classification. *Canadian Journal of Electrical and Computer Engineering*, 43(3), 170–173. <https://doi.org/10.1109/CJECE.2020.2970144>
- Prashanthi, V., Kanakala, S., Akila, V., & Harshavardhan, A. (2021). Music Genre Categorization using Machine learning Algorithms. *2021 International Conference on Computational Intelligence and Computing Applications (ICCICA)*, 1–4. <https://doi.org/10.1109/ICCICA52458.2021.9697137>
- Prince, S., Thomas, J. J., J, S. J., Priya, K. P., & Daniel, J. J. (2022). Music Genre Classification using Deep learning—A review. *2022 6th International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS)*, 1–5. <https://doi.org/10.1109/CSITSS57437.2022.10026394>
- Qothrunnada, F., Saidah, S., Hidayat, B., Busrizal Putri, T., & Darwindra. (2023). TONE DETECTION ON TERANIKA MUSICAL INSTRUMENT USING DISCRETE WAVELET TRANSFORM AND DECISION TREE CLASSIFICATION. *Jurnal Teknik Informatika (Jutif)*, 4(2), 373–380. <https://doi.org/10.52436/1.jutif.2023.4.2.570>
- S. J and K. S, "Obtain Better Accuracy Using Music Genre Classification System on GTZAN Dataset," *2022 IEEE North Karnataka Subsection Flagship International Conference (NKCon)*, Vijaypur, India, 2022, pp. 1-5, doi: 10.1109/NKCon56289.2022.10126991.
- S. U. Masruroh, A. S. Pratama, L. K. Wardhani, F. Fahrianto, W. A. Tsaqofi and R. A. Putri, "Classification of Popular Music Genre Using Convolutional Neural Network Method with Data Augmentation," *2023 Eighth International Conference on Informatics and Computing (ICIC)*,

Manado, Indonesia, 2023, pp. 1-4,
doi:
10.1109/ICIC60109.2023.1038199
5.

Salsabila, S. (n.d.). *MODUL DATA MINING
KLASIFIKASI PERTEMUAN 8
(ONLINE)*.

Yehezkiel, S. Y., & Suyanto, Y. (2022). Music
Genre Identification Using SVM and
MFCC Feature Extraction. *IJEIS
(Indonesian Journal of Electronics and
Instrumentation Systems)*, 12(2), 115.
<https://doi.org/10.22146/ijeis.70898>