

# Klasifikasi Genre Musik Berdasarkan Fitur *Mel Frequency Spectral Coefficient* Menggunakan *Random Forest*.

Reza Sefiyanti, Murinto

Universitas Ahmad Dahlan, Yogyakarta, Indonesia

\*Correspondence Author : [murintokusno@tif.uad.ac.id](mailto:murintokusno@tif.uad.ac.id)

## Abstrak

Klasifikasi genre musik merupakan proses pengelompokan lagu berdasarkan kemiripan elemen-elemen seperti frekuensi, harmoni, dan pola ritme. Proses klasifikasi secara manual menjadi tidak efisien ketika berhadapan dengan volume data yang besar. Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis genre musik menggunakan algoritma *Random forest* dengan menggabungkan fitur ekstraksi *Mel frequency cepstral coefficient (MFCC)* dan fitur spektral seperti *Chroma*, *Spectral contrast*, dan *Tonnetz*. Data yang digunakan berasal dari dataset *GTZAN* yang berisi 1000 file audio berdurasi 30 detik dan mewakili 10 genre musik berbeda. Tahapan penelitian meliputi ekstraksi fitur audio, *preprocessing*, pembagian data latih dan data uji, pelatihan model menggunakan *Random forest* dengan *Grid Search*, serta evaluasi performa menggunakan *Confusion Matrix* dan metrik akurasi. Hasil terbaik diperoleh dari kombinasi fitur *MFCC*, *delta*, *delta-delta* dengan perhitungan rata-rata dan standar deviasi, serta fitur spektral dengan perhitungan rata-rata, yang menghasilkan akurasi sebesar 76%. Temuan ini menunjukkan bahwa kombinasi fitur tersebut efektif dalam meningkatkan performa klasifikasi genre musik.

**Kata kunci:** genre musik, klasifikasi, *MFCC*, *random forest*, spektral.

## Abstract

Music genre classification is the process of grouping songs based on similarities in elements such as frequency, harmony, and rhythm patterns. Manual classification becomes inefficient when dealing with large volumes of data. This study aims to develop an automatic music genre classification system using the *Random forest* algorithm by combining feature extraction from *Mel frequency cepstral coefficient (MFCC)* and spectral features such as *Chroma*, *Spectral contrast*, and *Tonnetz*. The data used in this study comes from the *GTZAN* dataset, which consists of 1000 audio files, each 30 seconds long, representing 10 different music genres. The research stages include audio feature extraction, *preprocessing*, training and testing data splitting, model training using *Random forest* with *Grid Search*, and performance evaluation using a *Confusion Matrix* and accuracy metrics. The best result was achieved using a combination of *MFCC*, *delta*, and *delta-delta* features with mean and standard deviation calculations, along with spectral features using mean values, resulting in an accuracy of 76%. These findings indicate that the combination of features is effective in improving music genre classification performance..

**Keywords:** music genre, classification, *MFCC*, *random forest*, spectral.

## 1. Pendahuluan

Genre musik didefinisikan sebagai pengelompokan lagu berdasarkan kesamaan karakteristik seperti frekuensi musik, konten harmonik, dan struktur ritme [1]. Klasifikasi genre memiliki peran penting dalam memudahkan pendengar menemukan lagu sesuai preferensi. Pengelompokan secara manual, meskipun dapat dilakukan melalui pendengaran langsung, menjadi tidak efisien ketika menghadapi jumlah data audio yang besar [2]. Oleh karena itu, dibutuhkan sistem klasifikasi otomatis untuk mempercepat dan mempermudah proses tersebut.

Salah satu pendekatan yang banyak digunakan dalam sistem klasifikasi audio adalah pemanfaatan fitur audio seperti *Mel frequency cepstral coefficient (MFCC)*, yang meniru cara kerja telinga manusia dalam

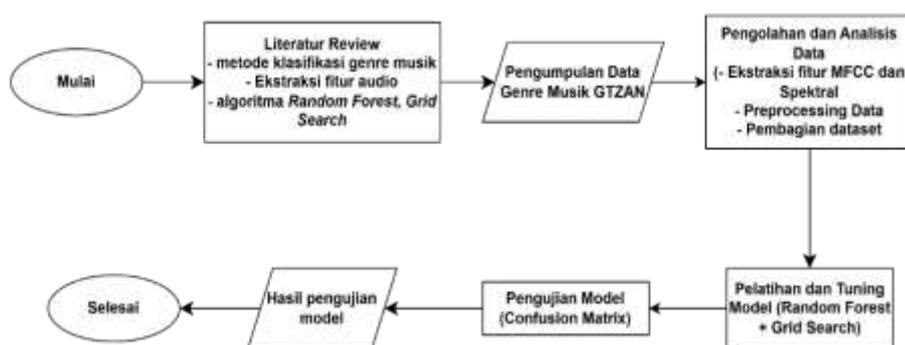
memisahkan komponen frekuensi sinyal [3]. Selain itu, fitur spektral seperti *Chroma*, *Spectral contrast*, dan *Tonnetz* mampu merepresentasikan dimensi nada, harmoni, serta tekstur suara, yang menjadi pembeda khas antar genre musik [4]. Proses klasifikasi genre musik juga membutuhkan dataset yang representatif. GTZAN merupakan salah satu dataset standar yang umum digunakan karena memuat 1000 file audio berdurasi 30 detik dari 10 genre populer seperti blues, country, jazz, rock, dan lainnya [5]. Untuk memaksimalkan akurasi klasifikasi, dibutuhkan algoritma yang mampu menangani jumlah fitur yang kompleks dan beragam. *Random forest* dipilih dalam penelitian ini karena termasuk metode *ensemble learning* yang kuat dan stabil, serta mampu menangani data berdimensi tinggi [6], [7].

Klasifikasi ini dilakukan dengan menggabungkan fitur *MFCC*, *delta*, dan *delta-delta*, serta fitur spektral yang diekstraksi dari sinyal audio. Proses pelatihan model melibatkan pembagian dataset menjadi data latih dan uji, serta tuning *hyperparameter* menggunakan *Grid Search* untuk menemukan konfigurasi model terbaik [8] [9]. Evaluasi sistem dilakukan berdasarkan akurasi yang dihasilkan pada data uji, dengan harapan sistem mampu memberikan klasifikasi yang andal dan dapat digunakan untuk mendukung berbagai aplikasi digital di bidang musik, seperti sistem rekomendasi dan pengorganisasian konten audio secara otomatis. *Machine Learning* adalah metode di mana mesin dilatih agar dapat merespons input atau skenario tertentu berdasarkan pengetahuan yang telah dipelajari sebelumnya [10]. Dengan kata lain, *Machine Learning* memberikan kemampuan kepada komputer untuk belajar menggunakan teknik statistik. Tujuannya adalah untuk mengurangi ketergantungan manusia dalam menyelesaikan masalah yang kompleks. *Machine Learning* memiliki berbagai aplikasi, seperti diagnosis medis, klasifikasi, mobil tanpa sopir, pembuatan algoritma, pengenalan gambar, prediksi, dan masih banyak lagi.

*Random Forest* merupakan metode ensemble yang menggabungkan beberapa pohon keputusan untuk mengklasifikasikan data ke dalam kelas tertentu. Algoritma dasar dari *Random Forest* [11] [12] adalah *decision tree*, di mana data input menjadi bagian atas (*root*) dan membentuk daun (*leaf*) yang digunakan untuk menentukan kelas. Algoritma ini mampu meningkatkan akurasi hasil pada data latih yang besar. Berdasarkan penjelasan di atas, sebuah penelitian dilakukan untuk menentukan metode klasifikasi lagu yang paling efektif dengan menggunakan pendekatan *Random Forest*. Fitur MFCC dan spektral digunakan untuk mengekstrak data dari dataset GTZAN.

## 2. Metode Penelitian

Dalam Gambar 1 diperlihatkan metodologi penelitian pada klasifikasi genre musik menggunakan ekstraksi fitur MFCC dan spektral menggunakan algoritma random forest.



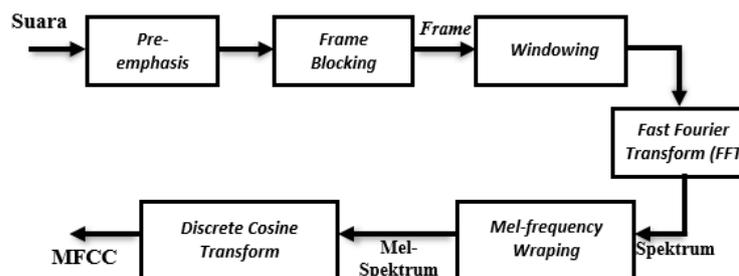
Gambar 1. Metodologi Penelitian Klasifikasi Genre Musik

Kajian literatur dilakukan untuk memahami metode klasifikasi genre musik yang telah ada sebelumnya, termasuk algoritma yang umum digunakan seperti *Random forest* dan teknik optimasi Grid Search. Selain itu, ditinjau pula metode ekstraksi fitur audio seperti *Mel frequency cepstral coefficient* (MFCC), serta fitur spektral seperti *Chroma*, *Spectral contrast*, dan *Tonnetz*. Kajian ini menjadi dasar dalam perancangan sistem klasifikasi pada penelitian ini. Dataset yang digunakan adalah Dataset GTZAN, yang terdiri dari 1000 file audio berdurasi 30 detik dalam format .wav, mencakup 10 genre: Blues, Classical,

Country, Disco, Hip Hop, Jazz, Metal, Pop, Reggae, dan Rock. Dataset ini menjadi input utama dalam proses klasifikasi. Tahapan ini mencakup:

#### 1). Ekstraksi Fitur Audio

Fitur audio diekstraksi dari sinyal *waveform* menggunakan metode MFCC beserta turunannya (delta dan delta-delta) untuk menangkap informasi frekuensi dan perubahan suara dari waktu ke waktu. Selain itu, ditambahkan fitur spektral seperti *Chroma* (untuk informasi *pitch*), *Spectral contrast* (untuk membedakan energi antar frekuensi), dan *Tonnetz* (untuk representasi tonal centroid). Proses MFCC terdiri dari *pre-emphasis*, *framing*, *windowing*, FFT, *mel-wrapping*, dan DCT. Gambar 2 merupakan proses dari fitur ekstraksi MFCC. Hasilnya diubah ke bentuk numerik menggunakan nilai statistik (mean dan standar deviasi).



Gambar 2. Proses MFCC

#### 2). Pre-Processing

Data hasil ekstraksi diperiksa untuk memastikan tidak ada nilai kosong (*missing value*). Label genre yang semula berbentuk teks dikodekan ke dalam format numerik menggunakan *LabelEncoder*. Kemudian seluruh fitur dinormalisasi menggunakan *StandardScaler* untuk menyamakan skala data dan meningkatkan performa pelatihan model.

#### 3). Pembagian Dataset

Dataset dibagi menjadi dua bagian, yaitu data latih (80%) dan data uji (20%) dengan menggunakan fungsi *train\_test\_split* dari pustaka *scikit-learn*. Data latih digunakan untuk membangun model, sedangkan data uji digunakan untuk mengevaluasi performa model yang telah dilatih.

Model klasifikasi dibangun menggunakan algoritma *Random forest Classifier*, yang bekerja dengan membentuk sejumlah *decision tree* secara paralel. Untuk memperoleh konfigurasi terbaik, dilakukan tuning hyperparameter menggunakan teknik *Grid Search*. Kombinasi hyperparameter yang diuji terdapat dalam Tabel 1. Model dengan hasil evaluasi terbaik digunakan untuk tahap pengujian akhir.

Tabel 1. Hyperparameter Random forest

| Hyperparameter    | Nilai yang diuji  |
|-------------------|-------------------|
| n_estimators      | 100, 200, 300     |
| max_depth         | 10, 20, None      |
| Criterion         | 'gini', 'entropy' |
| max_features      | 'sqrt', 'log2'    |
| min_samples_split | 2, 5              |

Evaluasi dilakukan menggunakan *Confusion Matrix* untuk mengukur kinerja model klasifikasi berdasarkan empat metrik utama: akurasi, presisi, recall, dan F1-score. Perhitungan didasarkan pada jumlah prediksi benar dan salah yang dikategorikan ke dalam True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN). Hasil akhir berupa model terbaik dengan konfigurasi optimal yang menunjukkan akurasi dan performa evaluasi tertinggi. Model ini digunakan sebagai dasar dalam penarikan kesimpulan atas keberhasilan sistem klasifikasi genre musik yang dikembangkan.

### 3. Hasil dan Pembahasan

Penelitian ini menggunakan dataset GTZAN, yang terdiri dari 1000 file audio berdurasi 30 detik dalam format .wav. Setiap file merupakan representasi dari satu dari sepuluh genre musik, yaitu: blues, classical, country, disco, hiphop, jazz, metal, pop, reggae, dan rock. Dataset ini diunduh dari Kaggle, diekstrak, lalu

diunggah ke Google Drive untuk proses pengolahan menggunakan Google Colab. Proses ekstraksi fitur dilakukan dengan menetapkan konfigurasi parameter sebagai berikut:

- a. `sample_rate = 22050` (menentukan jumlah sampel per detik)
- b. `pre_emphasis = 0.95` (memperkuat frekuensi tinggi pada sinyal audio)
- c. `frame_size = 0.025` detik dan `frame_stride = 0.01` detik (untuk membagi sinyal menjadi frame pendek)
- d. `n_fft = 512` (ukuran FFT yang digunakan)
- e. `n_mels = 40` (jumlah filter mel)
- f. `n_mfcc = 20` (jumlah koefisien MFCC yang dihasilkan per frame)

Langkah-langkah utama dalam ekstraksi fitur audio meliputi:

- a. *Pre-emphasis*: menyaring sinyal untuk memperkuat komponen frekuensi tinggi dan mengurangi efek noise dari frekuensi rendah.
- b. *Framing* dan *windowing*: membagi sinyal menjadi frame-frame pendek, lalu diterapkan *window hamming* untuk mengurangi distorsi tepi frame.
- c. FFT dan *Mel Filterbank*: mengubah sinyal ke domain frekuensi, lalu memetakan energi spektral ke skala mel dengan 40 filter.
- d. *Discrete Cosine Transform*: menghitung koefisien MFCC dari log-energi *mel spectrum*.
- e. *Delta* dan *Delta-delta*: menghitung turunan pertama dan kedua dari MFCC untuk menangkap perubahan antar frame dan percepatan nya.
- f. *Chroma*: distribusi energi dalam 12 kelas pitch.
- g. *Spectral contrast*: perbedaan energi antara puncak dan lembah di setiap sub-band.
- h. *Tonnetz*: representasi hubungan tonal berdasarkan centroid harmonik.

Seluruh fitur dari setiap frame kemudian dihitung nilai rata-rata (*mean*) dan/atau standar deviasi (*std*) nya untuk membentuk vektor numerik tetap.

### 3.1. Percobaan Ekstraksi Audio

Lima skenario percobaan dirancang untuk mengevaluasi kombinasi fitur terbaik

- a. Percobaan 1: Fitur MFCC dengan nilai *Mean* dan *Std*, menghasilkan total 40 fitur.
- b. Percobaan 2: Fitur MFCC, *Delta*, dan *Delta-delta* dengan nilai *Mean* dan *Std*, menghasilkan total 120 fitur.
- c. Percobaan 3: Fitur MFCC, *Delta* dan *Delta-delta*, *Chroma*, *Spectral contrast*, dan *Tonnetz* dengan nilai *Mean* dan Standar Deviasi, menghasilkan total 170 fitur.
- d. Percobaan 4: Fitur MFCC, *Delta* dan *Delta-delta* dengan nilai *Mean* dan *Std*, *Chroma*, *Spectral contrast*, dan *Tonnetz* dengan nilai *Mean* saja, menghasilkan total 145 fitur.
- e. Percobaan 5: Fitur MFCC, *Delta* dan *Delta-delta*, *Chroma*, *Spectral contrast*, dan *Tonnetz* dengan nilai *Mean*, menghasilkan total 85 fitur.

Setiap hasil ekstraksi disimpan ke dalam file .csv untuk digunakan pada tahap selanjutnya. Setelah fitur diekstraksi, data perlu dipersiapkan agar siap digunakan dalam pelatihan model. Proses preprocessing dimulai dengan memastikan bahwa tidak terdapat data yang hilang (*missing value*) dalam dataset. Selanjutnya, label genre musik yang semula berbentuk teks dikonversi menjadi format numerik menggunakan teknik *label encoding*. Setelah proses konversi, semua nilai fitur dinormalisasi dengan menggunakan metode *StandardScaler* untuk memastikan bahwa setiap fitur memiliki skala yang seragam, sehingga model tidak bias terhadap fitur tertentu. Dalam beberapa kasus, seleksi fitur juga dilakukan dengan metode *SelectKBest* guna meningkatkan efisiensi dan kinerja model. Dataset hasil preprocessing kemudian disimpan kembali dalam format .csv untuk digunakan pada tahap pembagian dan pelatihan model.

Dataset dibagi menggunakan *train\_test\_split* dengan rasio 80:20. Pembagian dilakukan secara stratified agar distribusi genre pada data uji tetap proporsional. Data uji digunakan untuk menilai performa model terhadap data yang belum pernah dilihat sebelumnya. Pelatihan dilakukan menggunakan algoritma *Random forest*. Untuk memperoleh hasil terbaik, dilakukan tuning hyperparameter menggunakan *Grid*

Search. Evaluasi setiap kombinasi parameter dilakukan menggunakan *5-fold cross validation* [13] Hyperparameter Model terbaik untuk tiap percobaan pada Tabel 2.

Tabel 2. *Hyperparameter* model terbaik

| Percobaan ke- | Criterion | Max_depth | Max_features | Min_samples_split | N_estimators |
|---------------|-----------|-----------|--------------|-------------------|--------------|
| Percobaan 1   | Gini      | None      | Sqrt         | 2                 | 300          |
| Percobaan 2   | Entropy   | 10        | Sqrt         | 2                 | 300          |
| Percobaan 3   | Gini      | 20        | log2         | 2                 | 200          |
| Percobaan 4   | Entropy   | 10        | Sqrt         | 5                 | 300          |
| Percobaan 5   | Entropy   | 20        | Sqrt         | 2                 | 300          |

Model diuji terhadap data uji menggunakan metrik:

a. Akurasi =  $\frac{TP+TN}{TP+TN+FP+FN}$  (1)

b. Presisi =  $\frac{TP}{TP+FP}$  (2)

c. Recall =  $\frac{TP}{TP+FN}$  (3)

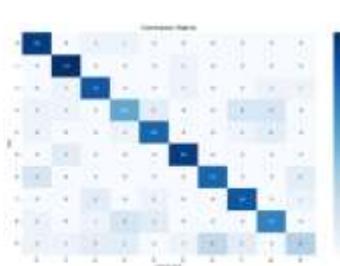
d. F1 – Score =  $2 \cdot \frac{Presisi \cdot Recall}{Presisi+Recall}$  (4)

**3.2 Hasil Confusion Matrix**

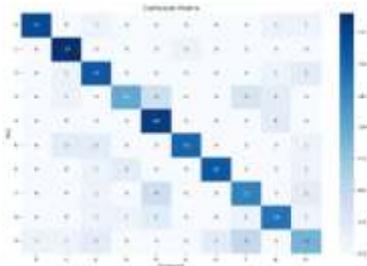
*Confusion Matrix* digunakan untuk melihat pola prediksi benar dan salah dari model terhadap data uji. Setiap percobaan menghasilkan matriks yang menunjukkan kekuatan dan kelemahan klasifikasi untuk masing-masing genre [14], [15]. Visualisasi *Confusion Matrix* dari masing-masing percobaan ditampilkan pada Gambar 3, Gambar 4, Gambar 5, Gambar 6 dan Gambar 7.



Gambar 3. Percobaan 1



Gambar 4. Percobaan 2



Gambar 5. Percobaan 3



Gambar 6. Percobaan 4



Gambar 7. Percobaan 5

Pada percobaan 1, model hanya menggunakan MFCC sehingga sering terjadi kesalahan klasifikasi, khususnya pada genre yang memiliki karakteristik spektral mirip seperti pop dan disco. Percobaan 2 memperlihatkan hasil lebih baik dengan tambahan fitur delta dan delta-delta, membantu dalam mengenali perubahan antar frame suara. Percobaan 3 memasukkan fitur spektral, memberikan akurasi yang lebih tinggi namun menunjukkan kecenderungan *overfitting*. Percobaan 4 memberikan hasil terbaik secara keseluruhan, dengan klasifikasi yang stabil dan minim kesalahan antar genre utama. Sedangkan pada percobaan 5, penghilangan standar deviasi dari fitur menyebabkan hilangnya informasi variasi sehingga akurasi menurun signifikan.

### 3.3 Hasil Pengujian Model

Setelah visualisasi Confusion Matrix disajikan untuk masing-masing percobaan, evaluasi kuantitatif terhadap performa model dilakukan menggunakan beberapa metrik utama, yaitu akurasi, presisi, recall, dan F1-score. Evaluasi ini bertujuan untuk memberikan gambaran yang lebih objektif mengenai kemampuan model dalam mengklasifikasikan genre musik berdasarkan kombinasi fitur yang digunakan pada setiap percobaan. Tabel 3 menyajikan ringkasan hasil pengujian model dari lima skenario yang telah dilakukan. Berdasarkan Tabel 3 percobaan ke-4 menghasilkan performa klasifikasi terbaik dibandingkan keempat percobaan lainnya. Kombinasi fitur MFCC, Delta, dan Delta-Delta yang diolah menggunakan nilai rata-rata dan standar deviasi mampu menangkap karakteristik audio sekaligus perubahan dinamis antar frame secara lebih mendalam. Penambahan fitur spektral seperti *Chroma*, *Spectral contrast*, dan *Tonnetz* yang hanya dihitung menggunakan nilai rata-rata juga berkontribusi dalam memperkaya informasi tonal dan harmonis dari setiap genre, tanpa menambah kompleksitas dimensi fitur secara berlebihan.

Tabel 3. Hasil Pengujian Model

| Percobaan | Fitur ekstraksi   | Statistik                          | Akurasi | Presisi | Recall | F1-Score |
|-----------|---|------------------------------------|---------|---------|--------|----------|
| 1         | MFCC  | Mean + Std                         | 0.68    | 0.68    | 0.68   | 0.67     |
| 2         | MFCC + Delta, Delta-delta   | Mean + Std                         | 0.73    | 0.72    | 0.73   | 0.72     |
| 3         | MFCC + Delta, Delta-delta + Spektral ( <i>Chroma</i> , <i>Contrast</i> , <i>Tonnetz</i> ) | Mean + Std                         | 0.73    | 0.75    | 0.73   | 0.73     |
| 4         | MFCC + Delta, Delta-delta + Spektral ( <i>Chroma</i> , <i>Contrast</i> , <i>Tonnetz</i> ) | MFCC (Mean + Std), Spektral (Mean) | 0.76    | 0.76    | 0.76   | 0.75     |
| 5         | MFCC + Delta, Delta-delta + Spektral ( <i>Chroma</i> , <i>Contrast</i> , <i>Tonnetz</i> ) | Mean                               | 0.59    | 0.61    | 0.59   | 0.58     |

Jumlah total fitur yang digunakan pada percobaan ke-4 adalah sebanyak 145, yang dinilai cukup optimal dalam merepresentasikan karakteristik audio secara komprehensif serta tetap menjaga stabilitas model dari risiko *overfitting*. Selain itu, pengaturan hyperparameter hasil tuning juga sangat berpengaruh terhadap peningkatan performa model. Konfigurasi terbaik diperoleh dengan  $n$  estimators = 300 untuk jumlah pohon klasifikasi yang stabil,  $max\_depth = 10$  untuk mengendalikan kompleksitas pohon,  $min\_samples\_split = 5$  guna mencegah percabangan terlalu dini, dan pemilihan kriteria entropy yang membuat model lebih peka terhadap distribusi kelas yang kompleks. Kombinasi fitur dan parameter inilah yang menghasilkan skor tertinggi pada seluruh metrik evaluasi.

Percobaan kedua dan ketiga juga menunjukkan performa yang baik dengan akurasi mencapai 73%, meskipun percobaan ketiga memiliki F1-score dan presisi yang sedikit lebih tinggi berkat kontribusi fitur spektral. Sementara itu, percobaan pertama (hanya MFCC) mencatat hasil sedang, dan percobaan kelima mencatat hasil terendah, yang menunjukkan bahwa menghilangkan informasi deviasi dari seluruh fitur dapat berdampak negatif terhadap kemampuan model dalam mengenali genre dengan akurat.

## 4. Kesimpulan

Penelitian ini menunjukkan bahwa metode *Random forest* dapat digunakan secara efektif untuk mengklasifikasikan genre musik dengan mengombinasikan fitur MFCC dan fitur spektral seperti *Chroma*, *Spectral contrast*, dan *Tonnetz*. Proses klasifikasi mencakup tahapan ekstraksi fitur dari dataset GTZAN, preprocessing, pembagian data, pelatihan, dan pengujian model. Dari lima skenario yang diuji, hasil terbaik diperoleh pada percobaan keempat dengan akurasi 76%, serta nilai presisi, recall, dan F1-score yang stabil di kisaran 0.75 hingga 0.76. Kombinasi fitur tersebut terbukti mampu memberikan performa klasifikasi yang paling akurat dan seimbang.

## DAFTAR PUSTAKA

- [1] D. R. Nugraa, "Aplikasi Klasifikasi Genre Musik Menggunakan Metode Naive Bayes Berbasis Desktop," *J. Inform. dan Teknol. Komput.* (J ..., vol. 01, no. 02, pp. 106–110, 2020.
- [2] M. L. Radhitya, P. S. Informatika, P. Studi, T. Informatika, and U. Udayana, "Klasifikasi Genre Musik Menggunakan Teknik Pembelajaran Mesin," *J. Tek. Inf. dan Komput.*, vol. 9, no. 1, pp. 1–9, 2023.
- [3] Y. Vita Via, I. Yuniar Purbasari, and A. Putra Pratama, "Analisa Algoritma Convolution Neural

- Network (Cnn) Pada Klasifikasi Genre Musik Berdasar Durasi Waktu,” *SCAN J. Teknol. dan Inf.*, vol. 17, no. 1, pp. 35–41, 2022.
- [4] P. Anggeli, Suroso, and M. Z. Agung, “Klasifikasi alat musik tradisional dengan metode machine learning menggunakan Librosa dan TensorFlow pada Python,” *J. Sains Komput. Inform.*, vol. 5, no. 2, pp. 949–956, 2021.
- [5] N. Amini, T. H. Saragih, M. R. Faisal, A. Farmadi, and F. Abadi, “Implementasi Algoritma Genetika Untuk Seleksi Fitur Pada Klasifikasi Genre Musik Menggunakan Metode Random Forest,” *J. Inform. Polinema*, vol. 9, no. 1, pp. 75–82, 2022, doi: 10.33795/jip.v9i1.1028.
- [6] F. Diba, “Analisis Random Forest Menggunakan Principal Component Analysis Pada Data Berdimensi Tinggi,” *Indones. J. Comput. Sci.*, vol. 12, no. 4, pp. 2152–2160, 2023, doi: 10.33022/ijcs.v12i4.3329.
- [7] C. Gopi, H. Kishan, and V. Kumari, “Information Processing in Agriculture Deep learning for rice leaf disease detection : A systematic literature review on emerging trends , methodologies and techniques,” *Inf. Process. Agric.*, no. April, 2024, doi: 10.1016/j.inpa.2024.04.006.
- [8] A. Fauzi, I. Syarif, and T. Badriyah, “Development of a Mobile Application for Plant Disease Detection using Parameter Optimization Method in Convolutional Neural Networks Algorithm,” vol. 11, no. 2, pp. 192–213, 2023.
- [9] S. Srinivasan, D. Francis, S. K. Mathivanan, H. Rajadurai, B. D. Shivahare, and M. A. Shah, “A hybrid deep CNN model for brain tumor image multi-classification,” *BMC Med. Imaging*, vol. 24, no. 1, pp. 1–21, 2024, doi: 10.1186/s12880-024-01195-7.
- [10] R. Bhagwat and Y. Dandawate, “A Review on Advances in Automated Plant Disease Detection,” vol. 11, no. 4, pp. 251–264, 2021.
- [11] Z. Sitorus, E. Hariyanto, and F. Kurniawan, “Implementasi Machine Learning Pada Sistem Pemetaan Daerah Rawan Banjir Di Desa Pahlawan Kabupaten Batu Bara,” *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 3, no. 3, pp. 285–290, 2022.
- [12] T. Sharma, R. Nair, and S. Gomathi, “Breast Cancer Image Classification using Transfer Learning and Convolutional Neural Network,” *Int. J. Mod. Res.*, vol. 2, no. 1, pp. 8–16, 2022.
- [13] M. H. Saleem, J. Potgieter, and K. M. Arif, “A weight optimization-based transfer learning approach for plant disease detection of New Zealand vegetables,” no. October, pp. 1–22, 2022, doi: 10.3389/fpls.2022.1008079.
- [14] Murinto, “Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network Classification,” vol. 18, no. 2, pp. 183–190, 2021, [Online]. Available: <https://eprints.umm.ac.id/79440/%0Ahttps://eprints.umm.ac.id/79440/1/Pendahuluan.pdf>
- [15] M. Fahmy Amin, “Confusion Matrix in Three-class Classification Problems: A Step-by-Step Tutorial,” *J. Eng. Res.*, vol. 7, no. 1, pp. 0–0, 2023, doi: 10.21608/erjeng.2023.296718.