

Pengaruh Metode MFCC Dan KNN Pada Music Information Retrieval Terhadap Klasifikasi Genre Musik

Ida Bagus Made Surya Widnyana^{a1}, Ngurah Agus Sanjaya ER^{a2}, I Putu Gede Hendra Suputra^{b3},
Luh Arida Ayu Rahning Putri^{b4}

^aProgram Studi Informatika, Universitas Udayana
Kuta Selatan, badung, Bali, Indonesia
¹Odesuryawidnyana@email.com
²agus_sanjaya@unud.ac.id.com

^b Program Studi Informatika, Universitas Udayana
Kuta Selatan, badung, Bali, Indonesia
³hendra.suputra@unud.ac.id
⁴rahningputri@unud.ac.id

Abstract

Music is an important art in daily life, but the abundance of choices makes song selection difficult. Music Information Retrieval (MIR) extracts information from music data, including genre classification. Mel-Frequency Cepstral Coefficients (MFCC) extract music features, and the K-Nearest Neighbor (KNN) algorithm classifies based on the distance of the training data. This study evaluates the accuracy of music genre classification using Mel Frequency Cepstral Coefficients (MFCC) and K-Nearest Neighbor (KNN) on five popular genres in Indonesia, namely pop, rock, dangdut, hip-hop, and jazz. The training data consists of 500 samples (100 per genre) with audio segments from the beginning, middle, and end with varying durations of 10 seconds, 20 seconds, and 30 seconds. The results show that the audio segment in the middle with a duration of 20 seconds, using the KNN classification method, has the highest accuracy with a value of $k=7$, achieving an accuracy of 68.67%. The middle audio segment is more representative and informative for genre classification. Therefore, it is recommended to use the 20-second middle segment with $k=7$ for more accurate classification using MFCC and KNN.

Keywords: *Music, K-Nearest Neighbor (KNN), Classification, Music Genre, Music Information Retrieval (MIR).*

Abstrak

Musik adalah seni yang penting dalam kehidupan sehari-hari, namun banyaknya pilihan membuat pemilihan lagu menjadi sulit. Music Information Retrieval (MIR) mengambil informasi dari data musik, termasuk klasifikasi genre. Mel-Frequency Cepstral Coefficients (MFCC) mengekstraksi fitur musik, dan algoritma K-Nearest Neighbor (KNN) mengklasifikasikan berdasarkan jarak data latih. Penelitian ini mengevaluasi akurasi klasifikasi genre musik menggunakan *Mel Frequency Cepstral Coefficients* (MFCC) dan *K-Nearest Neighbor* (KNN) pada lima genre populer di Indonesia, yaitu pop, rock, dangdut, hip-hop, dan jazz. Data latih terdiri dari 500 sampel (100 per genre) dengan potongan audio dari awal, tengah, dan akhir dengan variasi durasi 10 detik, 20 detik, dan 30 detik. Hasil menunjukkan titik potongan audio pada bagian tengah dengan durasi 20 detik, menggunakan metode klasifikasi KNN memiliki akurasi tertinggi dengan nilai $k=7$ memberikan akurasi terbaik sebesar 68.67%. Bagian tengah audio lebih representatif dan informatif untuk klasifikasi genre. Oleh karena itu, disarankan untuk menggunakan potongan tengah 20 detik dengan $k=7$ untuk klasifikasi yang lebih akurat menggunakan MFCC dan KNN.

Kata kunci: *Musik, K-Nearest Neighbor (KNN), Klasifikasi, Genre Musik, Music Information Retrieval (MIR).*

1. Pendahuluan

Musik adalah bagian penting dari kehidupan manusia dan dapat diakses dengan mudah melalui platform streaming. Namun, banyak pilihan lagu membuat pendengar kesulitan memilih lagu yang ingin didengarkan. Genre musik adalah kategori yang dibedakan berdasarkan ritme, harmoni, melodi, dan frekuensi, memudahkan masyarakat mengelompokkan dan mengidentifikasi musik yang mereka sukai. Genre musik sangat penting bagi anak muda millennial yang menjadi konsumen utama industri musik. Mereka tumbuh di era digital dan terpengaruh oleh berbagai jenis musik dari seluruh dunia. Klasifikasi genre membantu mereka menemukan musik sesuai selera mereka[4].

Music Information Retrieval (MIR) adalah bidang penelitian ilmu komputer yang mengembangkan teknik untuk mengekstraksi informasi dari data musik. Salah satu aplikasi MIR adalah klasifikasi genre musik berdasarkan karakteristik musik. Metode *Mel-Frequency Cepstral Coefficients* (MFCC) digunakan untuk mengekstraksi fitur dari data musik dengan mengubah sinyal suara ke domain frekuensi dan menghitung koefisien cepstral. MFCC berguna dalam analisis musik karena merepresentasikan ciri-ciri utama sinyal suara seperti tempo, harmoni, dan ritme[5].

Penelitian ini menggunakan algoritma *K-Nearest Neighbor* (KNN) merupakan klasifikasi dalam *machine learning* yang berdasarkan pada jarak antara data[7]. Dalam KNN menghitung jarak antara data uji dengan semua data audio musik dalam kumpulan data latih menggunakan *Euclidean distance* antara data yang dievaluasi dengan K sebagai penentu tetangga terdekat dalam data pelatihan[3]. Penggunaan metode MFCC dan algoritma KNN dalam klasifikasi genre musik di MIR menghadapi tantangan seperti variasi penampilan musik, kebisingan, dan perbedaan kualitas rekaman. Penelitian ini mengukur akurasi metode MFCC dan algoritma KNN dalam klasifikasi genre musik di MIR. Fokusnya adalah menguji akurasi menggunakan potongan audio dari awal, tengah, dan akhir dengan durasi 30 detik, 20 detik, dan 10 detik. Hasil penelitian ini diharapkan berkontribusi pada pengembangan MIR dan industri musik.

2. Metode Penelitian

Penelitian ini menggunakan metode *Mel Frequency Cepstral Coefficients* (MFCC) untuk mengambil ciri-ciri penting dari sinyal audio dan *K-Nearest Neighbor* (K-NN) untuk mengklasifikasikan genre musik. Metode MFCC mengekstrak fitur-fitur yang merepresentasikan karakteristik spektrum frekuensi sesuai dengan persepsi pendengaran manusia. Proses ekstraksi MFCC melibatkan beberapa tahapan, termasuk *pre-emphasis*, *frame blocking*, *windowing*, *FFT*, *Mel Frequency Wrapping*, dan akhirnya konversi ke domain waktu melalui cepstrum untuk mendapatkan koefisien MFCC [1]. Metode *K-Nearest Neighbor* (KNN) kemudian digunakan untuk mengklasifikasikan genre musik berdasarkan fitur yang diekstraksi menggunakan MFCC. Fitur MFCC dari data uji dibandingkan dengan fitur MFCC dari data latih menggunakan algoritma *K-Nearest Neighbor* (KNN). Jarak antara fitur data uji dan fitur data latih dihitung, dan data uji diklasifikasikan ke dalam genre musik yang memiliki jumlah tetangga terdekat (*nearest neighbors*) terbanyak dalam data latih[7].

2.1. Pengumpulan Data

Penelitian ini menggunakan 500 file musik dengan 5 genre yaitu pop, rock, dangdut, hip-hop, dan jazz, masing-masing dengan 100 file. Sumber data untuk genre rock, jazz, dan hip-hop diperoleh dari website Jamendo, sementara genre pop dan dangdut didownload dari YouTube dalam format .mp3 lalu dikonversi menjadi .wav menggunakan aplikasi dBpoweramp.

1. Pelabelan data

Pada tahap pelabelan, file-file musik yang di download pada website jamendo telah diberi label sesuai dengan genre yaitu rock, jazz, dan pop dan file-file musik yang di download pada Youtube dengan genre pop dan dangdut telah diberi label oleh saudari Ida Ayu Made Galih Wulandari yang bekerja di stasiun radio untuk memastikan validitas dalam proses klasifikasi.

2. Evaluasi Holdout

Evaluasi holdout dilakukan dengan membagi data menjadi dua bagian yaitu bagian untuk pelatihan dan bagian untuk pengujian [6]. Data latih terdiri dari 350 file sebagai data latih, sedangkan 150 file lainnya sebagai data uji yang dicocokkan dengan data latih.

3. Pemotongan Lagu

Seluruh file musik, baik yang digunakan sebagai data latih maupun data uji menggunakan audio dengan tiga titik potong yang berbeda yaitu.


- Pemotongan di awal merupakan bagian pertama dari setiap file musik, yang mencakup awal dari audio.
- Pemotongan di tengah merupakan bagian tengah dari setiap file musik, yang mencakup bagian tengah dari audio.
- Pemotongan di akhir merupakan Bagian terakhir dari setiap file musik, yang mencakup akhir dari audio.

Setiap bagian audio memiliki durasi yang berbeda yaitu 30 detik, 20 detik, dan 10 detik. Pemilihan berbagai durasi ini bertujuan untuk mencakup variasi yang mungkin terjadi dalam data uji, sehingga data latih dapat merepresentasikan berbagai jenis musik secara lebih komprehensif. Variasi durasi dan jenis musik dalam data latih merupakan aspek penting dalam penelitian *Music Information Retrieval* (MIR) ini, yang bertujuan untuk menghasilkan klasifikasi genre musik yang akurat dan dapat diandalkan.

2.2. Pre-processing

Penelitian ini mempersiapkan audio musik dengan format .wav dari berbagai sumber dan genre. Tahapan pertama adalah normalisasi menggunakan *Min-Max Scaler*. Proses ini melibatkan pembagian setiap sampel data dengan nilai tertinggi, sehingga semua data berada dalam rentang yang sama (0-1). Nilai minimum dan maksimum amplitudo audio dihitung, dan kemudian setiap sampel audio dinormalisasi untuk mempersiapkan data untuk proses lanjutan seperti ekstraksi fitur dan klasifikasi genre musik.

2.3. Mel-Frequency Cepstral Coefficients (MFCC)



Gambar 1. Diagram ekstraksi fitur


Tahap *Mel-Frequency Cepstral Coefficients* (MFCC) yang dapat dilihat pada gambar 1, proses awal dalam ekstraksi fitur dengan metode *Mel-Frequency Cepstral Coefficients* (MFCC) adalah pre-emphasis, yang bertujuan untuk menstabilkan nilai magnitude pada sinyal suara. Dengan demikian, efek peningkatan frekuensi yang tidak diinginkan dapat diurangi, sehingga kualitas sinyal menjadi lebih baik[2]. Tahapan berikutnya adalah frame blocking, yang membagi sinyal audio musik ke dalam frame-frame dengan waktu tertentu. Dengan demikian, kompleksitas analisis dapat diurangi dan efek diskontinuitas di awal dan akhir setiap frame dapat diatasi[1]. Selanjutnya, windowing dilakukan untuk

mengurangi efek diskontinuitas di awal dan akhir setiap frame serta mengurangi kebocoran spectral. Dengan menggunakan window hamming, efek diskontinuitas dan kebocoran spectral dapat diatasi, sehingga sinyal menjadi lebih stabil[7].

Kemudian FFT dilakukan untuk mengubah frame dari domain waktu ke domain frekuensi. Dengan demikian, spektrum frekuensi dapat dihasilkan dan digunakan untuk analisis sinyal selanjutnya, dihitung power spectrum (peridogram) pada setiap frame[1]. Mel Frequency Wrapping adalah proses penting dalam ekstraksi fitur suara yang menggabungkan Mel-Filter Bank dan perubahan skala frekuensi menjadi mel scale, sesuai dengan persepsi pendengaran manusia. Proses ini mengubah skala frekuensi menjadi mel scale, dimana perbedaan frekuensi kecil pada frekuensi rendah dianggap lebih penting. Mel-Filter Bank terdiri dari filter-filter yang lebih sensitif terhadap frekuensi rendah dibandingkan dengan frekuensi tinggi, meniru cara kerja telinga manusia. Dengan demikian, spektrum frekuensi yang dihasilkan oleh FFT diproses menggunakan filter bank yang berfokus pada frekuensi penting bagi telinga manusia. Dengan Mel Frequency Wrapping, fitur suara yang dihasilkan lebih akurat dan sesuai dengan cara kerja telinga manusia, sehingga meningkatkan performa pengenalan suara[7]. Cepstrum dilakukan untuk mengkonversi nilai-nilai mel yang telah diperoleh kembali ke dalam domain waktu. Dengan demikian, efek kebocoran waktu dapat diurangi dan koefisien cepstrum menjadi lebih stabil.

Mel-Frequency Cepstral Coefficients (MFCC) dilakukan untuk menghasilkan ekstraksi berupa matriks dua dimensi dengan ukuran $tframe \times jkoef$, dengan baris berupa frame dan kolom berupa koefisien. Tframe adalah jumlah frame yang terbentuk dan jkoef adalah jumlah koefisien MFCC yang diinginkan. Pada penelitian ini menggunakan koefisien MFCC berjumlah 20[8]. Setiap elemen dalam matriks merepresentasikan nilai koefisien MFCC pada setiap frame audio. Matriks ini kemudian dirata-ratakan untuk menghasilkan satu vektor yang mewakili keseluruhan audio. Vektor fitur MFCC ini digunakan sebagai masukan untuk tahap klasifikasi[7].

2.4. K-Nearest Neighbor (KNN)



Gambar 2. Diagram Klasifikasi dengan KNN

Tahap klasifikasi yang dapat dilihat pada gambar 2, data fitur yang dihasilkan dari ekstraksi fitur dalam bentuk matriks dua dimensi dengan ukuran $tframe \times jkoef$, dengan baris berupa frame dan kolom berupa koefisien. Tframe adalah jumlah frame yang terbentuk dan jkoef adalah jumlah koefisien MFCC yang diinginkan. Pada penelitian ini menggunakan koefisien MFCC berjumlah 20[8]. Matriks ini kemudian dirata-ratakan untuk menghasilkan satu vektor yang mewakili keseluruhan audio. Vektor fitur ini digunakan sebagai referensi data pembelajaran untuk melakukan klasifikasi menggunakan algoritma *K-Nearest Neighbor*. Proses klasifikasi dimulai dengan menentukan nilai k sebagai jumlah tetangga terdekat untuk setiap jenis suara, kemudian menghitung jarak antara data uji dengan semua data audio musik dalam kumpulan data latih menggunakan *Euclidean distance*[7]. Data diurutkan berdasarkan jarak terkecil sebanyak nilai k yang telah ditentukan, dan kelas ditentukan berdasarkan frekuensi terbanyak dari data latih sebanyak nilai k yang telah ditentukan. Hasil klasifikasi diberikan dalam bentuk prediksi genre musik. Dari hasil prediksi tersebut digunakan untuk menentukan akurasi dari hasil klasifikasi, sehingga dapat diukur tingkat keakuratan dari algoritma yang digunakan[3].

3. Hasil dan Pembahasan

Penelitian ini menggunakan normalisasi, ekstraksi fitur dengan MFCC, dan klasifikasi dengan KNN pada dataset 500 file audio WAV dengan 5 genre musik, masing-masing 100 file audio. Data dibagi menjadi 350 untuk latih dan 150 untuk uji. Pengujian dilakukan dengan akurasi menggunakan tiga potongan audio lagu dengan durasi berbeda (30 detik, 20 detik, dan 10 detik).

3.1. Pengujian terhadap potongan audio dari awal, tengah, dan akhir dengan durasi yang bervariasi

Pengujian dilakukan dengan menerapkan metode *K-Nearest Neighbor* (KNN) dan ekstraksi fitur *Mel Frequency Cepstral Coefficients* (MFCC) pada potongan audio dari awal, tengah, dan akhir dengan variasi durasi 10 detik, 20 detik, dan 30 detik. Setiap file audio musik dibagi menjadi tiga bagian, yaitu bagian awal, tengah, dan akhir. Kemudian, model KNN dilatih menggunakan data latih dan diuji menggunakan data uji dengan nilai k yang ganjil, dimulai dari k = 3 hingga k = 15. Langkah ini bertujuan untuk mengetahui akurasi klasifikasi berdasarkan berbagai nilai k pada masing-masing durasi audio dan potongan audio yang berbeda. Hasil pengujian menunjukkan bagaimana variasi durasi dan posisi potongan audio mempengaruhi akurasi pada klasifikasi genre musik. Berikut hasil klasifikasi dapat dilihat pada tabel 2.

Tabel 2. Hasil Akurasi terhadap potong audiodan durasi yang berbeda dengan metode KNN

Nilai K	Akurasi KNN								
	Bagian Awal Audio			Bagian Tengah Audio			Bagian Akhir audio		
	Durasi			Durasi			Durasi		
	10 detik	20 detik	30 detik	10 detik	20 detik	30 detik	10 detik	20 detik	30 detik
3	53.33%	49.33%	56.67%	58.67%	64.67%	61.33%	46.00%	52.00%	53.33%
5	52.00%	53.33%	56.00%	62.00%	68.00%	63.33%	48.00%	56.00%	60.00%
7	51.33%	52.67%	57.33%	62.00%	68.67%	61.33%	46.67%	54.00%	60.67%
9	54.00%	48.00%	56.67%	62.00%	66.00%	58.67%	50.00%	57.33%	62.67%
11	54.00%	52.00%	56.67%	58.67%	66.67%	59.33%	46.67%	55.33%	62.67%
13	51.33%	56.00%	54.67%	60.67%	64.67%	60.67%	46.67%	55.33%	61.33%
15	52.00%	50.67%	54.67%	62.00%	65.33%	60.00%	49.33%	56.00%	59.33%

Hasil Klasifikasi yang dapat dilihat pada tabel 2, bagian tengah audio menunjukkan akurasi terbaik, dengan akurasi berkisar antara 46,00% hingga 68,67% dari pada durasi 10 detik dan 30 detik. Durasi 10 detik dan 30 detik menghasilkan akurasi yang kurang baik dibandingkan dengan durasi 20 detik yang memberikan hasil terbaik dengan akurasi 68,67% pada bagian tengah audio dengan nilai k=7. Pada gambar yang dapat dilihat pada tabel 3, dapat divisualisasikan dalam bentuk grafik dari hasil akurasi terhadap potong audio yang berbeda dengan metode *K-Nearest Neighbor* (KNN) dan ekstraksi fitur *Mel Frequency Cepstral Coefficients* (MFCC) pada potongan audio dari awal, tengah, dan akhir berdasarkan tiga durasi yang berbeda pada setiap file audio musik yaitu 10 detik, 20 detik, dan 30 detik. Potongan bagian audio yang memiliki akurasi terbaik adalah potongan bagian tengah audio. Secara keseluruhan, bagian tengah potongan audio menunjukkan akurasi klasifikasi yang lebih baik daripada

bagian awal dan akhir. Dalam durasi 10 detik, akurasi klasifikasi berkisar antara 46,00% hingga 62,00%, dengan hasil terbaik pada potong tengah dengan nilai k = 5, 7, 9, dan 15 mencapai 62,00%. Pada durasi 20 detik akurasi meningkat cukup signifikan, berkisar antara 48.00% hingga 68.67%, dengan hasil tertinggi pada potong tengah dengan nilai k=7 mencapai 68.67%. Pada durasi 30 detik, akurasi berkisar antara 53,33% hingga 63,33%, dengan hasil terbaik pada potong tengah dengan nilai k=5 mencapai 63,33%. Hasil visualisasi dalam bentuk gambar grafik dapat dilihat pada tabel 3.

Tabel 3. tabel visualisasi Hasil Akurasi terhadap potong audiodan durasi yang berbeda dengan metode KNN

Bagian Audio	Grafik akurasi untuk potongan audio awal, tengah, dan akhir dengan durasi 10 detik, 20 detik, dan 30 detik.
Potong Awal	<p>Accuracy vs. K for Different audio cut section and durations</p> <p>Duration: /content/drive/MyDrive/SKRIPSI/Hasil MFCC SKRIPSI/Hasil MFCC /Potong Awal/extracted_features_potong_awal_10_seconds.csv Duration: /content/drive/MyDrive/SKRIPSI/Hasil MFCC SKRIPSI/Hasil MFCC /Potong Awal/extracted_features_potong_awal_20_seconds.csv Duration: /content/drive/MyDrive/SKRIPSI/Hasil MFCC SKRIPSI/Hasil MFCC /Potong Awal/extracted_features_potong_awal_30_seconds.csv</p>
Potong Tengah	<p>Accuracy vs. K for Different audio cut section and durations</p> <p>Duration: /content/drive/MyDrive/SKRIPSI/Hasil MFCC SKRIPSI/Hasil MFCC /Potong Tengah/extracted_features_potong_tengah_30_seconds.csv Duration: /content/drive/MyDrive/SKRIPSI/Hasil MFCC SKRIPSI/Hasil MFCC /Potong Tengah/extracted_features_potong_tengah_20_seconds.csv Duration: /content/drive/MyDrive/SKRIPSI/Hasil MFCC SKRIPSI/Hasil MFCC /Potong Tengah/extracted_features_potong_tengah_10_seconds.csv</p>
Potong Akhir	<p>Accuracy vs. K for Different audio cut section and durations</p> <p>Duration: /content/drive/MyDrive/SKRIPSI/Hasil MFCC SKRIPSI/Hasil MFCC /Potong Akhir/extracted_features_potong_akhir_20_seconds.csv Duration: /content/drive/MyDrive/SKRIPSI/Hasil MFCC SKRIPSI/Hasil MFCC /Potong Akhir/extracted_features_potong_akhir_30_seconds.csv Duration: /content/drive/MyDrive/SKRIPSI/Hasil MFCC SKRIPSI/Hasil MFCC /Potong Akhir/extracted_features_potong_akhir_10_seconds.csv</p>

Dari hasil pengujian menunjukkan bahwa durasi dan bagian potong audio berbeda memiliki dampak signifikan pada kinerja algoritma klasifikasi K-Nearest Neighbor (KNN). Bagian tengah audio menunjukkan akurasi terbaik, dengan akurasi berkisar antara 46,00% hingga 68.67% pada durasi 10 detik, 20 detik, dan 30 detik. Durasi 20 detik memberikan hasil terbaik dengan akurasi 68.67% pada bagian tengah audio dengan nilai $k=7$.

Oleh karena itu, disarankan untuk fokus pada audio bagian tengah dengan durasi sekitar 20 detik dan menggunakan nilai $k=7$ untuk hasil yang optimal. Dari hasil tersebut dapat disimpulkan bahwa audio bagian tengah memberikan performa klasifikasi yang lebih baik, terutama pada durasi 20 detik dan nilai $k=7$. Hal ini menunjukkan bahwa audio bagian tengah lebih representatif dan informatif untuk klasifikasi genre musik. Oleh karena itu, disarankan untuk fokus pada audio bagian tengah dengan durasi sekitar 20 detik dan menggunakan nilai $k=7$ untuk hasil yang optimal.

4. Kesimpulan

Pengujian dilakukan dengan menerapkan K-Nearest Neighbor (KNN) dan ekstraksi fitur Mel Frequency Cepstral Coefficients (MFCC) pada potongan audio dari awal, tengah, dan akhir dengan variasi durasi 10 detik, 20 detik, dan 30 detik. Hasil pengujian menunjukkan bahwa potongan bagian tengah audio memiliki akurasi terbaik, dengan akurasi berkisar antara 46,00% hingga 68.67%. Durasi 20 detik memberikan hasil terbaik dengan akurasi 68.67% pada potongan tengah audio dengan nilai $k=7$.

Dari hasil pengujian, dapat disimpulkan bahwa audio bagian tengah memberikan akurasi klasifikasi yang lebih baik, terutama pada durasi 20 detik dan nilai $k=7$. Hal ini menunjukkan bahwa audio bagian tengah lebih representatif dan informatif untuk klasifikasi genre musik. Oleh karena itu, disarankan untuk fokus pada audio bagian tengah dengan durasi sekitar 20 detik dan menggunakan nilai $k=7$ untuk hasil yang optimal.

Referensi

- [1] As Sarofi, M. A., Irhamah, I., & Mukarromah, A. (2020). Identifikasi Genre Musik dengan Menggunakan Metode Random Forest. *Jurnal Sains Dan Seni ITS*, 9(1), 79–86. <https://doi.org/10.12962/j23373520.v9i1.51311>
- [2] Adhinata, F. D., Rakhmadani, D. P., & Segara, A. J. T. (2021). Pengenalan Jenis Kelamin Manusia Berbasis Suara Menggunakan MFCC dan GMM. *Journal of Dinda : Data Science, Information Technology, and Data Analytics*, 1(1), 28–33. <https://doi.org/10.20895/dinda.v1i1.198>
- [3] Harsemadi, G., Sudarma, M., & Pramaita, N. (2017). Implementasi Algoritma K-Nearest Neighbor pada Perangkat Lunak Pengelompokan Musik untuk Menentukan Suasana Hati. *Majalah Ilmiah Teknologi Elektro*, 16(1), 14–20. <https://doi.org/10.24843/mite.1601.03>
- [4] Habibi, A. M., & Santika, R. R. (2020). Implementasi Algoritma K-Nearest Neighbor dalam Menentukan Jurusan Menggunakan Metode Euclidean Distance Berbasis Web Pada SMP Setia Gama. *Skanika*, 3(4), 7–14.
- [5] Kurniawan, S., & Agustian, S. (2021). *Music Information Retrieval Menggunakan k-NN dan Cosine Similarity*. November, 94–101.
- [6] Nasution, N., Djahara, K., & Zamsuri, A. (2015). Evaluasi Kinerja Akademik Mahasiswa Menggunakan Algoritma Naive Bayes (Studi Kasus: Fasilkom Unilak). *Jurnal Teknologi Informasi Dan Komunikasi Digital Zone*, 6(2), 1–11.[7]
- [7] Prasetyo, P. D., Suta Wijaya, I. G. P., & Yudo Husodo, A. (2019). Klasifikasi Genre Musik Menggunakan Metode Mel-Frequency Cepstrum Coefficients dan K-Nearest Neighbors Classifier. *Jurnal Teknologi Informasi, Komputer, Dan Aplikasinya (JTika)*, 1(2), 189–197. <https://doi.org/10.29303/jtika.v1i2.41>
- [8] Tridarma, P., & Endah, S. N. (2020). *Pengenalan Ucapan Bahasa Indonesia Menggunakan MFCC dan Recurrent Neural Network*. 11, 36–44.

This page is intentionally left blank.