

Klasifikasi Kidung Dewa Yadnya Menggunakan Kombinasi Metode MFCC dan KNN

I Ketut Prawira Adhisastro¹, Gede Sukadarmika², Fajar Purnama³

[Submission: 23-01-2026, Accepted: 22-04-2026]

Abstract— Kidung Dewa Yadnya is a sacred Balinese vocal art that plays a vital role in Hindu religious ceremonies. However, its existence faces serious challenges in the modern era. Globalization and the dominance of popular culture among the younger generation tend to shift their attention away from local music and traditions due to a preference for modern genres better known through digital media. This puts traditional culture at risk of declining interest and sustainability without appropriate documentation or revitalization strategies. Therefore, this study aims to develop a classification system for Kidung Dewa Yadnya using digital signal processing and artificial intelligence approaches. The Mel-Frequency Cepstral Coefficients (MFCC) method is used to extract acoustic characteristics from sound signals because of its ability to represent human auditory perception. The MFCC process includes pre-emphasis, framing, windowing, fast fourier transform, mel filter bank, discrete cosine-transform, and cepstral lifting stages. The extracted feature vectors are used as input for the K-Nearest Neighbor (KNN) algorithm for classification. The research data were obtained from voice recordings of Kidung Dewa Yadnya singers in .wav format. The test results showed the highest accuracy of 81.25% at $k = 1$ and $k = 2$, with an average accuracy above 78%. This value indicates that the combination of MFCC and KNN methods is effective in recognizing the acoustic patterns of kidung. This research is expected to support the preservation of Balinese culture through the digitization of kidung and serve as a basis for the development of an artificial intelligence-based traditional music classification system.

Intisari— Kidung Dewa Yadnya merupakan seni vokal sakral Bali yang memegang peranan penting dalam pelaksanaan upacara keagamaan Hindu. Namun demikian, keberadaannya menghadapi tantangan serius di era modern. Globalisasi dan dominasi budaya populer di kalangan generasi muda cenderung mengalihkan perhatian dari musik dan tradisi lokal karena preferensi terhadap genre modern yang lebih dikenal melalui media digital. Kondisi ini menempatkan budaya tradisional pada risiko menurunnya minat dan keberlanjutan apabila tidak disertai dengan upaya dokumentasi dan revitalisasi yang tepat. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi Kidung Dewa Yadnya dengan memanfaatkan pendekatan pengolahan sinyal digital dan kecerdasan buatan. Metode Mel-Frequency Cepstral Coefficients (MFCC) digunakan untuk mengekstraksi karakteristik akustik dari sinyal suara

karena kemampuannya dalam merepresentasikan persepsi pendengaran manusia. Proses MFCC meliputi tahapan pre-emphasis, framing, windowing, Fast Fourier Transform (FFT), mel filter bank, Discrete Cosine Transform (DCT), dan cepstral lifting. Vektor ciri hasil ekstraksi selanjutnya digunakan sebagai masukan bagi algoritma K-Nearest Neighbor (KNN) untuk proses klasifikasi. Data penelitian diperoleh dari rekaman suara penyanyi Kidung Dewa Yadnya dalam format .wav. Hasil pengujian menunjukkan bahwa akurasi tertinggi sebesar 81,25% diperoleh pada nilai $k = 1$ dan $k = 2$, dengan rata-rata akurasi di atas 78%. Nilai tersebut menunjukkan bahwa kombinasi metode MFCC dan KNN efektif dalam mengenali pola akustik kidung. Penelitian ini diharapkan dapat mendukung upaya pelestarian budaya Bali melalui digitalisasi kidung serta menjadi dasar pengembangan sistem klasifikasi musik tradisional berbasis kecerdasan buatan.

Kata Kunci— Kidung Dewa Yadnya; MFCC; KNN; Kasifikasi.

I. PENDAHULUAN

Budaya Bali sangat kaya dengan seni tembang dan karawitan. Tidak hanya karya-karya yang diwariskan secara turun-temurun, namun juga karya baru masih terus bermunculan, baik yang bersifat klasik maupun kontemporer. Di antara berbagai bentuk nyanyian tradisional Bali, terdapat seni tembang yang terdiri dari empat jenis utama yaitu gegendingan, pupuh, kidung, dan kakawin [1]. Di antara keempatnya, kidung, khususnya kidung Dewa Yadnya, memiliki posisi yang sangat penting dalam konteks keagamaan karena berfungsi sebagai media komunikasi spiritual kepada Ida Sang Hyang Widhi Wasa dan menjadi bagian tak terpisahkan dalam pelaksanaan upacara keagamaan.

Namun demikian, keberadaannya menghadapi tantangan serius di era modern. Globalisasi dan dominasi budaya populer di kalangan generasi muda cenderung mengalihkan perhatian dari musik dan tradisi lokal karena preferensi terhadap genre modern yang lebih dikenal melalui media digital [2][3]. Kondisi ini menempatkan budaya tradisional pada risiko menurunnya minat dan keberlanjutan apabila tidak disertai dengan upaya dokumentasi dan revitalisasi yang tepat. Oleh karena itu, perlu dikembangkan sistem otomatis yang mampu mengenali dan mengklasifikasikan jenis-jenis kidung secara efektif. Untuk tujuan tersebut, diperlukan pendekatan teknologi yang tepat dan efisien.

Mel-Frequency Cepstral Coefficients (MFCC) merupakan metode ekstraksi fitur audio yang banyak digunakan karena mampu merepresentasikan karakteristik suara berdasarkan persepsi pendengaran manusia. MFCC terbukti efektif dalam menangkap fitur-fitur penting dari sinyal suara, terutama dalam domain frekuensi, dan telah diaplikasikan secara luas dalam pengenalan suara dan musik [4][5]. Mengingat kidung Dewa

p-ISSN:1693 – 2951; e-ISSN: 2503-2372

¹Mahasiswa, Program Studi Magister Teknik Elektro Universitas Udayana, Gedung Pacasarjana Universitas Udayana Jl. PB Sudirman Denpasar-Bali, Kode Pos : 80323 (telp: 0361-555225 ; e-mail: prawira.adhisastro@yahoo.com)

^{2,3}Dosen, Jurusan Teknik Elektro dan Komputer Fakultas Teknik Universitas Udayana, Jln. Jalan Kampus Bukit Jimbaran 80361 INDONESIA (telp: 0361-703315; fax: 0361-4321; e-mail: ²sukadarmika@unud.ac.id; ³fajarpurnama@unud.ac.id)



Yadnya memiliki struktur melodi dan ritme yang khas dan kompleks, penggunaan MFCC menjadi penting karena mampu menangkap detail spektral yang membedakan satu jenis kidung dengan lainnya.

Beberapa penelitian terdahulu menunjukkan bahwa MFCC memiliki keunggulan dibandingkan metode lain seperti Linear Predictive Coding (LPC). Dalam penelitian yang dilakukan oleh Siti [6]. Hasil akurasi pengenalan emosi dengan ekstraksi fitur LPC sebesar 28%, sedangkan hasil akurasi dengan ekstraksi fitur MFCC sebesar 61,33%. MFCC menunjukkan akurasi yang lebih tinggi dibandingkan dengan LPC karena kemampuannya merepresentasikan karakteristik sinyal dalam domain persepsi manusia. LPC lebih fokus pada model sumber suara dan sering kurang sensitif terhadap dinamika frekuensi kompleks seperti yang terdapat pada kidung.

Dengan demikian, MFCC lebih unggul untuk pengolahan sinyal audio karena menggabungkan representasi spektrum yang akurat dengan model persepsi telinga manusia, menjadikannya sangat sesuai untuk pengenalan suara dengan karakteristik kompleks seperti pada musik tradisional.

Di sisi lain, algoritma K-Nearest Neighbor (KNN) dipilih sebagai metode klasifikasi karena kesederhanaan, efektivitas, serta kemampuannya dalam menangani data non-linier yang umum dijumpai pada pengenalan pola suara [7]. KNN bekerja berdasarkan kedekatan data uji dengan data latih, sehingga sangat bergantung pada kualitas fitur yang diekstraksi [8]. Kombinasi MFCC dan KNN terbukti menghasilkan performa yang baik dalam berbagai studi pengenalan suara, namun masih sangat jarang diaplikasikan untuk klasifikasi musik tradisional, apalagi pada kidung Dewa Yadnya yang belum banyak diteliti secara teknologi.

Pemilihan fokus pada kidung Dewa Yadnya didasarkan pada urgensi pelestariannya. Kidung ini memiliki nilai spiritual yang tinggi, fungsi ritual yang sakral, serta kekayaan linguistik dalam bahasa Bali Madya yang mulai jarang dipahami oleh generasi muda. Dengan menjadikan kidung Dewa Yadnya sebagai objek kajian, penelitian ini tidak hanya bertujuan untuk mencari akurasi sistem klasifikasi suara berbasis MFCC dan KNN, tetapi juga mendukung pelestarian warisan budaya Bali secara digital.

Dengan demikian, penelitian ini diharapkan mampu memberikan kontribusi nyata dalam dua aspek utama: pertama, sebagai upaya pelestarian dan digitalisasi seni kidung Dewa Yadnya dan menjadi dasar pengembangan sistem klasifikasi otomatis kidung Dewa Yadnya untuk aplikasi edukatif, dokumentasi digital, dan platform budaya. dan kedua, sebagai pengembangan metode klasifikasi suara berbasis MFCC dan KNN yang dioptimalkan untuk musik tradisional dengan struktur kompleks..

II. STUDI PUSTAKA

Penelitian-penelitian sebelumnya menunjukkan keberhasilan metode MFCC dan KNN dalam berbagai konteks pengenalan suara.

- Pada penelitian ini telah berhasil membuat sistem pengenalan pembicara dengan tingkat akurasi terbaik sebesar 87.5% dan 1.80277 detik dengan menggunakan K = 5 dalam implementasi pembuka kunci menggunakan suara [9].

- klasifikasi genre musik tradisional Indonesia berdasarkan pengenalan pola suara menggunakan metode Support Vector Machine(SVM) telah berhasil dibuat dengan hasil analisis sistem memiliki rata-rata akurasi sebesar 83%, nilai presisi sebesar 83%, nilai recall sebesar 85%, dan f1-score sebesar 83% [10].
- Berdasarkan hasil pengujian pada sistem identifikasi dan klasifikasi nada secara real- time, disimpulkan bahwa sistem ini mampu mengidentifikasi nada alat musik kecapi secara real-time menggunakan metode Mel Frequency Cepstral Coefficient dan klasifikasi K-Nearest Neighbor. Akurasi terbaik diperoleh dengan nilai windowing120, mencapai 81.42%, karena windowing mengurangi efek diskontinuitas pada ujung- ujung frame [11].
- Hasil Pengujian usability pada aplikasi didapatkan bahwa nilai rata-rata diatas 3, yang berarti bahwa perangkat lunak SekARAI yang telah diimplementasikan telah memenuhi nsur Usability dan selain itu perangkat lunak tersebut mudah digunakan serta dimengerti oleh para pengguna. Aplikasi Pengenalan Suara Tembang Sekar Alit telah dievaluasi dengan metode confusion matrix diperoleh bahwa pengujian algoritma MFCC mendapatkan hasil akurasi sebesar 76,6% [12].
- Penelitian yang dilakukan oleh Kardiyasa dan Santika dalam Majalah Ilmiah Teknologi Elektro [13] menerapkan metode Support Vector Machine (SVM) untuk deteksi anomali pada jaringan FTTH dengan tahapan preprocessing, seleksi fitur, serta validasi model menggunakan cross-validation. Hasil evaluasi menunjukkan performa yang tinggi berdasarkan metrik akurasi, presisi, recall, dan F1-score, sehingga menegaskan bahwa SVM efektif dalam membangun batas pemisah (hyperplane) optimal pada data yang bersifat non-linear.

Dari berbagai penelitian tersebut dapat disimpulkan bahwa MFCC unggul dalam merepresentasikan karakteristik suara, sedangkan KNN efektif dalam pengklasifikasian data suara. Namun, penelitian yang secara khusus mengkaji pengenalan kidung Bali, terutama Kidung Dewa Yadnya, masih jarang dilakukan.

A. Kidung Dewa Yadnya

Kidung mempunyai arti yang sama dengan kata kidung atau lagu, yang berarti nyanyian atau syair yang dinyanyikan [14][15]. Kidung Dewa Yadnya sendiri adalah jenis kidung atau nyanyian suci yang biasanya dinyanyikan dalam upacara Dewa Yadnya, yaitu persembahan yang ditujukan kepada para dewa dalam tradisi Agama Hindu, khususnya di Bali.

Kidung Dewa Yadnya memiliki beberapa bagian penting yang masing-masing memiliki fungsi dan makna tersendiri dalam upacara keagamaan seperti Purwaka yang merupakan Bagian pembuka atau pendahuluan dari kidung yang berisi salam, pujian, dan permohonan izin kepada dewa-dewa untuk memulai nyanyian suci, kemudian Pengastawa yaitu Bagian inti dari kidung yang berisi puji-pujian kepada para dewa [14]

B. Mel Frequency Cepstrum Coefficients (MFCC)

Metode Mel-Frequency Cepstral Coefficients (MFCC) diperkenalkan oleh Davis dan Mermelstein tahun 1980 sebagai teknik ekstraksi ciri suara yang meniru cara kerja pendengaran

manusia[16][17]. MFCC adalah teknik yang digunakan dalam pengolahan sinyal suara untuk ekstraksi fitur. Teknik ini menganalisis frekuensi suara menggunakan skala mel, yang mencerminkan bagaimana manusia mendengar frekuensi. MFCC mengkonversi sinyal suara dari domain waktu ke domain frekuensi, lalu kecepstrum, dengan memecahnya menjadi koefisien yang mewakili spektrum suara[18]. Koefisien ini digunakan untuk mengidentifikasi karakteristik unik dari sinyal suara, sehingga sangat berguna dalam aplikasi seperti pengenalan suara dan analisis audio.

Tahapan utama dalam proses MFCC meliputi:

1. Pre-Emphasis

Menonjolkan frekuensi tinggi agar rasio sinyal terhadap noise meningkat dan spektrum suara lebih seimbang.

$$y(n) = x(n) - \alpha x(n-1) \quad (1)$$

2. Frame Blocking

Sinyal dibagi menjadi beberapa frame berdurasi 20–25 ms dengan tumpang tindih 30–50% untuk menjaga kestabilan sinyal selama analisis.

3. Windowing

Setiap frame dikalikan dengan fungsi jendela (misalnya *Hamming window*) untuk mengurangi efek diskontinuitas antarframe.

$$y(n) = x(n)w(n), 0 \leq n \leq N-1 \quad (2)$$

4. Fast Fourier Transform (FFT)

Mengubah sinyal dari domain waktu ke domain frekuensi untuk memperoleh representasi spektrum.

$$x[k] = \sum_{n=0}^{N-1} y[n] * e^{-\frac{2\pi jkn}{N}}, n = 0, 1, \dots, N-1 \quad (3)$$

5. Mel Filter Bank

Menerapkan sekumpulan filter berbasis skala mel untuk meniru persepsi frekuensi manusia.

$$mel(k) = 2595 * \log_{10}\left(1 + \frac{f}{700}\right) \quad (4)$$

6. Discrete Cosine Transform (DCT)

Mengubah spektrum log-magnitude hasil *Mel Filter Bank* menjadi koefisien cepstral (MFCC) yang mewakili karakteristik utama suara.

$$C_n = \sum_{k=1}^K (\log S_k) \cos \left[n \left(k - \frac{1}{2} \right) \frac{\pi}{K} \right] \quad (5)$$

7. Cepstral Liftering

Menormalkan dan memperhalus distribusi koefisien cepstral agar fitur lebih stabil dan berkualitas.

$$w[n] = \left\{ 1 + \frac{L}{\sin} \sin \left(\frac{n\pi}{L} \right) \right\} \quad (6)$$

Dengan tahapan tersebut[19], MFCC mampu menghasilkan representasi suara yang mendekati cara manusia mengenali bunyi, menjadikannya metode yang sangat efektif untuk sistem pengenalan suara dan musik tradisional seperti *Kidung Dewa Yadnya*.

C. Machine Learning

Teknologi pembelajaran mesin (ML) adalah sistem yang dirancang agar dapat belajar secara mandiri tanpa instruksi langsung dari penggunaannya [20]. ML juga dapat mempelajari data yang ada dan data yang ia peroleh sehingga bisa melakukan tugas tertentu [21][22]. Tugas yang dapat dilakukan oleh ML pun sangat beragam, tergantung dari apa yang ia pelajari.

I Ketut Prawira Adhisastira : Klasifikasi Kidung Dewa Yadnya...

Dalam konteks ini, pembelajaran mesin memiliki kemampuan untuk mengumpulkan data secara mandiri. ML juga dapat menganalisis data yang tersedia serta data yang diperolehnya, sehingga dapat melaksanakan berbagai tugas. Beragam tugas yang dapat dilakukan oleh ML bergantung pada data yang dipelajarinya.

D. Metode KNN

Algoritma K-Nearest Neighbor (KNN) adalah algoritma pembelajaran mesin yang bersifat non-parametrik dan lazy learning [23]. Metode non-parametrik berarti bahwa metode ini tidak membuat asumsi tentang distribusi data yang mendasarinya [24]. KNN mengklasifikasikan data uji berdasarkan kedekatannya dengan sejumlah (k) data latih terdekat. Prosesnya dimulai dengan menentukan nilai k , menghitung jarak antara data uji dan seluruh data latih menggunakan rumus Euclidean Distance:

$$d_{xy} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (7)$$

Nilai jarak terkecil menunjukkan kedekatan antar data. Setelah jarak dihitung, KNN memilih k tetangga terdekat, kemudian menentukan kelas dari data uji berdasarkan mayoritas kelas pada tetangga tersebut. Akurasi model dihitung dengan membandingkan jumlah prediksi yang benar terhadap total data uji. Karena kesederhanaan dan efektivitasnya dalam mengenali pola non-linier, KNN banyak digunakan untuk pengenalan pola suara dan klasifikasi audio seperti Kidung Dewa Yadnya.

III. METODOLOGI

Penelitian ini bertujuan untuk membuat sistem klasifikasi Kidung Dewa Yadnya dengan memanfaatkan metode Mel-Frequency Cepstral Coefficients (MFCC) untuk ekstraksi ciri suara dan K-Nearest Neighbor (KNN) sebagai algoritma klasifikasi. Penelitian dilakukan secara eksperimental melalui tahapan pengumpulan data, pengolahan data audio, ekstraksi fitur, klasifikasi, serta evaluasi hasil menggunakan parameter akurasi.

A. Pengumpulan Data

Data pada penelitian ini didapat dari merekam suara narasumber. Jumlah data yang digunakan pada penelitian ini yaitu 80 data suara kidung Dewa Yadnya, dimana ada 10 narasumber dan masing-masing nara sumber menghasilkan 8 data suara. Kidung Dewa Yadnya yang dipilih dalam klasifikasi yaitu :

Kawitan wargasari yang terdiri dari :

1. purwakaning
2. Sukanya arja

Wargasari yang terdiri dari :

1. Asep Pejati
2. Bhatara makire tedun

Pupuh wargasari yang terdiri dari :

1. ida ratu sakeng luhur
2. asep menyan
3. Bhatara sakeng luhur
4. Bhatara sampun rawuh




B. Pengolahan Data Audio

Setiap rekaman audio disimpan dalam format .wav dengan durasi antara 1–3 menit. Rekaman dilakukan di lingkungan yang relatif tenang untuk meminimalkan gangguan suara latar. Data kemudian dikelompokkan berdasarkan jenis kidung dan dipisahkan menjadi dua set, yaitu data latih (training set) sebesar 70% dan data uji (testing set) sebesar 30% dari total data yang tersedia.

C. Ekstraksi Fitur MFCC

File suara Kidung berformat .wav dibaca menggunakan library Scipy, yang menyediakan fungsi numerik efisien untuk pengolahan data audio. Setelah proses pembacaan, dilakukan ekstraksi fitur menggunakan metode MFCC, yang meniru sistem pendengaran manusia dengan penyaringan linier pada frekuensi di bawah 1000 Hz dan logaritmik pada frekuensi di atas 1000 Hz.



Gambar 1: Flowchart MFCC

- **Pre-Emphasis**
Pre-Emphasis adalah langkah pertama dalam ekstraksi fitur MFCC. Proses ini akan mempertahankan frekuensi tinggi dalam spektrum yang biasanya hilang atau dihilangkan dalam proses produksi suara. Pre-emphasis bertujuan untuk mengurangi rasio noise terhadap sinyal sehingga dapat meningkatkan kualitas suatu sinyal dan menyeimbangkan spektrum suara yang disuarakan.
- **Frame Blocking**
Frame Blocking adalah tahap dimana sinyal suara disegmentasi menjadi beberapa frame. Secara umum, dalam proses pemblokiran frame, setiap frame berdurasi 20-25 milidetik dengan porsi tumpang tindih (M) antara satu frame dengan frame lainnya sebesar 30-50% dari panjang frame. Panjang frame (N) yang digunakan dalam proses ini sangat berpengaruh. Untuk sukses dalam analisis spektral. Semakin panjang ukuran frame yang digunakan, semakin banyak resolusi frekuensi yang akan dituju, namun hal ini akan mempengaruhi resolusi waktu yang dihasilkan.
- **Windowing**
Pada proses Windowing dilakukan tahap pembobotan data untuk setiap frame yang dibentuk pada proses sebelumnya dengan menggunakan fungsi window. Windowing ini dilakukan untuk mengurangi gap setelah proses frame blocking

- **Fast Fourier Transform**
Fast Fourier Transform (FFT) merupakan pengembangan dari Discrete Fourier Transform (DFT) yang bertujuan untuk mengubah sinyal dari domain waktu ke domain frekuensi. Pada langkah FFT ini, masing-masing N sampel dikonversi dari domain waktu ke domain frekuensi. Setelah mendapatkan nilai FFT, nilai ini digunakan untuk menghitung densitas spektral energi. Densitas spektral energi ini akan digunakan untuk memetakan nilai FFT ke bank filter yang akan digunakan pada tahap selanjutnya.
- **Mel Filter Bank**
Selanjutnya dilakukan perhitungan bank filter terhadap sinyal data yang diperoleh dari proses FFT sebelumnya. Untuk menyederhanakan nilai ini diubah menjadi satuan dB, sehingga akan dihasilkan nilai bank filter signal.
- **Discrete Cosinus Transform (DCT)**
Pada tahap ini, nilai spektrum mel pada domain frekuensi akan diubah menjadi domain waktu untuk mendapatkan nilai koefisien.
- **Cepstral Lifting**
Pada proses Cepstral lifting ini merupakan teknik yang digunakan untuk memperkecil sensitivitas koefisien cepstral yang dihasilkan dari tahapan utama dalam ekstraksi fitur menggunakan MFCC. Proses ini berfungsi untuk meningkatkan kualitas pengenalan suara. Setelah melakukan perhitungan yang sama untuk setiap nilai koefisien cepstral, maka akan didapatkan nilai koefisien cepstral terfilter. Nilai ini nantinya akan digunakan sebagai dataset pada tahap klasifikasi.

D. K-Nearest Neighbor



Gambar 2 : Flowchart Metode KNN

Dapat dilihat pada gambar 2 flowchart metode KNN yang merupakan alur dari Metode K-nearest Neighbor. Algoritma K-Nearest Neighbor (KNN) diawali dengan memasukkan data uji (testing) yang belum diketahui kelasnya. Setelah data uji diterima, langkah selanjutnya adalah menentukan nilai K, yaitu jumlah tetangga terdekat yang akan dijadikan dasar pengambilan keputusan. Nilai K ini berperan penting karena memengaruhi hasil klasifikasi. Selanjutnya, sistem menghitung jarak antara data uji dengan seluruh data latih (training) menggunakan metode pengukuran jarak tertentu, yang pada umumnya menggunakan Euclidean Distance. Jarak yang diperoleh menunjukkan tingkat kemiripan antara data uji dan data latih, di mana jarak yang lebih kecil menandakan tingkat kemiripan yang lebih tinggi. Sebagai contoh, misalkan terdapat

satu data uji dengan dua fitur, yaitu $X=(4,3)$ serta tiga data latih seperti berikut:

- Data latih A: (2,3), kelas = C1
- Data latih B: (5,4), kelas = C1
- Data latih C: (6,1), kelas = C2

Perhitungan jarak Euclidean dilakukan menggunakan persamaan:

$$d_{xy} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (7)$$

Berdasarkan hasil perhitungan jarak Euclidean terhadap tiga data latih terdekat, diperoleh nilai jarak seperti yang ditunjukkan pada Tabel berikut.

TABEL I
Nilai Jarak Euclidean

Data Latih	Kelas	Jarak Euclidean
A	C1	2
B	C1	1.41
C	C2	2.83

Berdasarkan hasil perhitungan tersebut, jarak kemudian diurutkan dari yang terkecil hingga terbesar, yaitu data B (1,41), data A (2), dan data C (2,83). Apabila ditentukan nilai $K = 2$, maka dua tetangga terdekat yang dipilih adalah data B dan data A. Kedua data tersebut memiliki label kelas yang sama, yaitu C1, sehingga kelas mayoritas yang diperoleh adalah C1.

Dengan demikian, berdasarkan hasil perhitungan K-Nearest Neighbor, data uji $X=(4,3)$ diklasifikasikan ke dalam kelas C1. Proses ini menunjukkan bahwa algoritma KNN menentukan kelas suatu data berdasarkan kedekatan jarak dan dominasi label kelas pada sejumlah tetangga terdekat yang telah ditentukan sebelumnya.

Setelah mendapatkan jarak antara data training dan data testing, kemudian menentukan kelas sesuai jarak minimum dari range yang telah ditentukan kemudian ditampilkan hasil klasifikasi dan akurasi.

Akurasi kemudian diperoleh dengan rumus:

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Data Uji}} \times 100\% \quad (8)$$

Misalnya, jika model KNN menguji 30 sampel dan 25 di antaranya diklasifikasikan dengan benar, maka akurasi model adalah 83,3%.

E. Penentuan Nilai K Optimal

Dalam algoritma K-Nearest Neighbor (KNN), pemilihan nilai K merupakan parameter krusial yang secara langsung memengaruhi performa klasifikasi. Nilai K yang terlalu kecil (misalnya $K=1$) cenderung menghasilkan model dengan variansi tinggi (overfitting) [25], karena keputusan klasifikasi hanya bergantung pada satu tetangga terdekat. Sebaliknya, nilai K yang terlalu besar dapat menyebabkan model kehilangan sensitivitas terhadap pola lokal (underfitting), karena keputusan didasarkan pada terlalu banyak tetangga yang mungkin berasal dari kelas berbeda.

Untuk menentukan nilai K yang optimal, penelitian ini menggunakan pendekatan empirical testing, yaitu dengan menguji beberapa nilai K secara bertahap dari $K=1$ hingga $K=5$. Rentang ini dipilih berdasarkan pertimbangan:

- Jumlah sampel relatif kecil (80 dan 50 data)
- Distribusi kelas seimbang (10 data per kelas)
- Untuk menghindari nilai K yang terlalu besar dibanding jumlah data per kelas

Evaluasi dilakukan menggunakan metrik accuracy, precision, recall, dan F1-score berdasarkan confusion matrix. Nilai K terbaik dipilih berdasarkan akurasi tertinggi yang diperoleh pada data pengujian.

F. Skenario Pengujian

Pengujian dilakukan dengan 2 skenario, skenario pertama menggunakan 8 kelas kidung dan skenario kedua menggunakan 5 kelas kidung, dengan tahap pengujian yang sama. Data suara Kidung di-input dan dibaca, kemudian dilakukan ekstraksi ciri menggunakan metode MFCC, sehingga diperoleh nilai MFCC pada data suara tersebut. Data tersebut kemudian dibagi menjadi 70% data latih dan 30% data uji. Pada tahap selanjutnya, metode KNN digunakan untuk mencari nilai K terbaik, dengan menguji nilai K dari 1 hingga 5. Akurasi pada setiap percobaan K diukur berdasarkan confusion matrix yang dihasilkan, dan diperoleh hasil performa (precision, recall, F1 score, dan accuracy) untuk setiap nilai K yang diuji.

IV. HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini berupa kumpulan data audio kidung Dewa Yadnya yang diperoleh melalui proses perekaman langsung dan pengumpulan dari sumber digital. Setiap file audio disimpan dalam format .wav agar dapat diolah menggunakan tools SciPy dan pustaka pemrosesan sinyal lainnya di Python.

A. Dataset Skenario Pertama (8 Kelas Kidung)

Pada skenario pertama, sistem diuji menggunakan 8 kelas kidung Dewa Yadnya, di mana masing-masing kelas berisi 10 file audio, sehingga total data yang digunakan adalah 80 file audio.

TABEL II
Dataset Skenario Pertama

No.	Kelas Kidung	Jumlah File Audio
1	Purwakaning	10
2	Sukanya arja	10
3	Asep pejati	10
4	Bhatara makire tedun	10
5	Ida ratu sakeng luhur	10
6	Asep menyan	10
7	Bhatrane sakeng luhur	10
8	Bhatara Sampun Rawuh	10



Data pada setiap kelas memiliki durasi antara 1–3 menit. Pada tahap ini, seluruh file audio dikonversi menjadi bentuk numerik dan dilakukan proses ekstraksi fitur menggunakan metode MFCC.

B. Dataset Skenario Kedua (5 Kelas Kidung)

Pada skenario kedua, dilakukan pengujian ulang sistem dengan menggunakan 5 kelas kidung yang juga masing-masing berisi 10 file audio, sehingga total terdapat 50 data audio. Pemilihan lima kelas ini didasarkan pada hasil analisis awal bahwa beberapa kelas kidung memiliki pola suara yang sangat mirip, sehingga pengurangan jumlah kelas dilakukan untuk mengukur pengaruhnya terhadap tingkat akurasi sistem.

TABEL III
Dataset Skenario Kedua

No.	Kelas Kidung	Jumlah File Audio
1	Purwakaning	10
2	Sukanya arja	10
3	Asep pejati	10
4	Ida ratu sakeng luhur	10
5	Asep menyan	10

Kedua skenario dataset ini digunakan untuk membandingkan sejauh mana jumlah kelas berpengaruh terhadap tingkat akurasi sistem klasifikasi. Dengan adanya dua konfigurasi tersebut, hasil penelitian dapat memberikan gambaran yang lebih komprehensif mengenai performa metode MFCC dan KNN dalam mengenali karakteristik akustik kidung Dewa Yadnya.

C. Hasil Ekstraksi Ciri MFCC

Berikut adalah tabel hasil ekstraksi ciri MFCC dari skenario pertama yang menggunakan 8 kelas kidung dan skenario kedua yang menggunakan 5 kelas kidung.

TABEL IV
Hasil Ekstraksi Ciri MFCC 8 Kelas Kidung

	0	1	2		69	label
0	598.3192	225.345	-86.9515		35.20017	1_purwakaning
1	432.8958	374.1093	320.3267		44.87547	1_purwakaning
2	433.2113	397.9486	9.875854		41.71566	1_purwakaning
....						
591	390.9394	283.9357	-149.689		42.69174	8_bhatara sampun rawuh

TABEL V
Hasil Ekstraksi Ciri MFCC 5 Kelas Kidung

	0	1	2		69	label
0	598.3192	225.345	-86.9515		35.20017	1_purwakaning
1	432.8958	374.1093	320.3267		44.87547	1_purwakaning

2	433.2113	397.9486	9.875854		41.71566	1_purwakaning
....						
371	552.1943	341.3328	-182.817		48.37566	6_asep menyan

Hasil ekstraksi setiap file audio berupa 70 nilai fitur (35 mean + 35 standar deviasi) yang disimpan dalam file CSV sebagai dataset siap pakai.

Fitur hasil ekstraksi dinormalisasi menggunakan StandardScaler agar semua nilai memiliki skala yang seimbang. Selanjutnya dataset dibagi menjadi dua bagian:

- Data latih (70%)
- Data uji (30%)

D. Klasifikasi Menggunakan KNN

Algoritma KNN digunakan untuk mengklasifikasikan kidung berdasarkan kemiripan nilai fitur MFCC. Proses dilakukan dengan beberapa percobaan nilai K (1–5) untuk menentukan hasil akurasi terbaik. Evaluasi kinerja sistem dilakukan menggunakan akurasi, precision, recall, dan F1-score dari classification_report milik scikit-learn.

E. Hasil Pengujian Skenario Pertama

Pada skenario pertama, menggunakan 8 kelas kidung Dewa Yadnya, dengan total 80 file audio yang dimana terdapat masing-masing 10 file per kelas. Dari hasil pengujian K-Nearest Neighbor didapat classification report, untuk hasil tersebut didapat seperti tabel V.

TABEL VI
Hasil Pengujian Skenario Pertama

Nilai K	Akurasi	classification report
1	65,1 7%	<pre> precision recall f1-score support 1_purwakaning 0.8000 0.8000 0.8000 20 2_sukanya arja 0.8125 0.9286 0.8667 14 3_asep pejati 0.8214 0.7667 0.7931 30 4_bhatara makire 0.4583 0.5000 0.4783 22 5_ida ratu sakeng luhur 0.6250 0.7407 0.6780 27 6_asep menyan 0.5000 0.3333 0.4000 21 7_bhatara sakeng luhur 0.6190 0.5652 0.5909 23 8_bhatara sampun rawuh 0.5652 0.6190 0.5909 21 accuracy 0.6517 178 macro avg 0.6502 0.6567 0.6497 178 weighted avg 0.6493 0.6517 0.6469 178 </pre>
		<pre> precision recall f1-score support 1_purwakaning 0.8000 0.8000 0.8000 20 2_sukanya arja 0.8125 0.9286 0.8667 14 3_asep pejati 0.8214 0.7667 0.7931 30 4_bhatara makire 0.4583 0.5000 0.4783 22 5_ida ratu sakeng luhur 0.6250 0.7407 0.6780 27 6_asep menyan 0.5000 0.3333 0.4000 21 7_bhatara sakeng luhur 0.6190 0.5652 0.5909 23 8_bhatara sampun rawuh 0.5652 0.6190 0.5909 21 accuracy 0.6517 178 macro avg 0.6502 0.6567 0.6497 178 weighted avg 0.6493 0.6517 0.6469 178 </pre>
3	64,6 1%	

TABEL VII
Hasil Pengujian Skenario Kedua

			precision	recall	f1-score	support
		1_purwakaning	0.7826	0.9000	0.8372	20
		2_sukanya arja	0.9231	0.8571	0.8889	14
		3_asep pejati	0.7667	0.7667	0.7667	30
		4_bhatara makire	0.5217	0.5455	0.5333	22
		5_ida ratu sakeng luhur	0.6333	0.7837	0.6967	27
		6_asep menyen	0.5333	0.3810	0.4444	21
		7_bhatara sakeng luhur	0.5500	0.4783	0.5116	23
		8_bhatara sampun rawuh	0.5000	0.5714	0.5333	21
		accuracy			0.6461	178
		macro avg	0.6513	0.6585	0.6478	178
		weighted avg	0.6433	0.6461	0.6417	178
4	64,0 4%		precision	recall	f1-score	support
		1_purwakaning	0.8182	0.9000	0.8571	20
		2_sukanya arja	0.8462	0.7857	0.8148	14
		3_asep pejati	0.7742	0.8000	0.7869	30
		4_bhatara makire	0.4286	0.5455	0.4800	22
		5_ida ratu sakeng luhur	0.6296	0.6296	0.6296	27
		6_asep menyen	0.6154	0.3810	0.4706	21
		7_bhatara sakeng luhur	0.5789	0.4783	0.5238	23
		8_bhatara sampun rawuh	0.5200	0.6190	0.5652	21
		accuracy			0.6404	178
		macro avg	0.6514	0.6424	0.6410	178
weighted avg	0.6462	0.6404	0.6377	178		
5	59,5 5%		precision	recall	f1-score	support
		1_purwakaning	0.7500	0.7500	0.7500	20
		2_sukanya arja	0.6875	0.7857	0.7333	14
		3_asep pejati	0.7576	0.8333	0.7937	30
		4_bhatara makire	0.4583	0.5000	0.4783	22
		5_ida ratu sakeng luhur	0.6552	0.7837	0.6786	27
		6_asep menyen	0.5000	0.2657	0.3636	21
		7_bhatara sakeng luhur	0.4444	0.3478	0.3902	23
		8_bhatara sampun rawuh	0.4231	0.5238	0.4681	21
		accuracy			0.5955	178
		macro avg	0.5845	0.5913	0.5820	178
weighted avg	0.5884	0.5955	0.5863	178		

Pada tabel VI Hasil Pengujian Skenario Pertama yang dimana pada classification report terdapat precision, recall, dan f1 Score. Yang dimana precision merupakan tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem, kemudian recall merupakan tingkat keberhasilan sistem dalam menentukan Kembali sebuah informasi, dan F1 Score merupakan salah satu perhitungan evaluasi dalam informasi temu Kembali yang mengkombinasi recall dan precision. Hasil dari pengujian menunjukkan bahwa tingkat akurasi tertinggi diperoleh pada nilai k = 1 dan 2 dengan akurasi sebesar 65,17%. Akurasi pada k = 1 dan k = 2 sama karena model KNN memakai pembobotan jarak, sehingga tetangga terdekat yang dominan menghasilkan prediksi identik untuk kedua nilai K.

F. Hasil Pengujian Skenario Kedua

Pada skenario kedua, jumlah kelas dikurangi menjadi 5 kelas kidung, masing-masing terdiri dari 10 file audio dengan total 50 data. Proses pengujian dilakukan dengan parameter dan tahapan yang sama seperti pada skenario pertama. Hasil pengujian menunjukkan peningkatan yang signifikan pada akurasi sistem, untuk hasil tersebut didapat seperti tabel VI.

Nilai K	Akurasi	classification report				
1	81,25 %		precision	recall	f1-score	support
		1_purwakaning	0.8095	0.8500	0.8293	20
		2_sukanya arja	0.8125	0.9286	0.8667	14
		3_asep pejati	0.9062	0.9667	0.9355	30
		5_ida ratu sakeng luhur	0.8000	0.7407	0.7692	27
		6_asep menyen	0.6667	0.5714	0.6154	21
		accuracy			0.8125	112
		macro avg	0.7998	0.8115	0.8032	112
		weighted avg	0.8067	0.8125	0.8078	112
		2	81,25 %		precision	recall
1_purwakaning	0.8095			0.8500	0.8293	20
2_sukanya arja	0.8125			0.9286	0.8667	14
3_asep pejati	0.9062			0.9667	0.9355	30
5_ida ratu sakeng luhur	0.8000			0.7407	0.7692	27
6_asep menyen	0.6667			0.5714	0.6154	21
accuracy					0.8125	112
macro avg	0.7998			0.8115	0.8032	112
weighted avg	0.8067			0.8125	0.8078	112
3	75,00 %				precision	recall
		1_purwakaning	0.7500	0.9000	0.8182	20
		2_sukanya arja	0.8571	0.8571	0.8571	14
		3_asep pejati	0.8333	1.0000	0.9091	30
		5_ida ratu sakeng luhur	0.7019	0.5926	0.6667	27
		6_asep menyen	0.4786	0.3810	0.4211	21
		accuracy			0.7500	112
		macro avg	0.7346	0.7461	0.7344	112
		weighted avg	0.7362	0.7500	0.7364	112
		4	75,00 %		precision	recall
1_purwakaning	0.7200			0.9000	0.8000	20
2_sukanya arja	0.9167			0.7857	0.8462	14
3_asep pejati	0.8333			1.0000	0.9091	30
5_ida ratu sakeng luhur	0.8000			0.5926	0.6800	27
6_asep menyen	0.4737			0.4286	0.4500	21
accuracy					0.7500	112
macro avg	0.7487			0.7414	0.7372	112
weighted avg	0.7488			0.7500	0.7486	112
5	74,11 %				precision	recall
		1_purwakaning	0.7391	0.8500	0.7907	20
		2_sukanya arja	0.7857	0.7857	0.7857	14
		3_asep pejati	0.7838	0.9667	0.8657	30
		5_ida ratu sakeng luhur	0.8182	0.6667	0.7347	27
		6_asep menyen	0.5000	0.3810	0.4324	21
		accuracy			0.7411	112
		macro avg	0.7254	0.7300	0.7218	112
		weighted avg	0.7311	0.7411	0.7295	112

Hasil pengujian pada tabel VI menunjukkan peningkatan akurasi sistem yang signifikan, dengan nilai tertinggi sebesar 81,25% pada k = 1 dan k = 2. Kesamaan nilai akurasi pada beberapa K disebabkan oleh pola jarak antara data uji dan data latih yang relatif seragam, sehingga penambahan jumlah tetangga tidak memengaruhi hasil mayoritas kelas yang dipilih. Peningkatan akurasi ini juga menunjukkan bahwa pengurangan jumlah kelas dapat menurunkan kompleksitas klasifikasi dan mengurangi tumpang tindih fitur antar kelas, sehingga sistem lebih mudah membedakan karakteristik kidung ketika variasi antar kelas tidak terlalu banyak dan pola suaranya lebih terpisah.



G. Analisis Hasil Pengujian

Hasil pengujian dari kedua skenario menunjukkan perbedaan yang cukup jelas. Secara ringkas, perbandingan hasil ditampilkan pada Tabel VII.

TABEL VIII
Analisis Hasil Pengujian


No.	Jumlah Kelas	Jumlah Data	Akurasi Tertinggi %	Nilai K Terbaik
1	8 Kelas	80 Data	65,17%	1 dan 2
2	5 Kelas	50 Data	81,25%	1 dan 2

Berdasarkan tabel di atas, dapat disimpulkan bahwa semakin sedikit jumlah kelas yang diuji, tingkat akurasi sistem meningkat. Hal ini disebabkan karena kompleksitas data berkurang, dan algoritma KNN dapat mengenali pola ciri khas tiap kidung dengan lebih efektif. Namun, hasil ini juga menunjukkan bahwa sistem masih memiliki keterbatasan dalam menangani jumlah kelas yang banyak, terutama ketika terdapat kemiripan pola frekuensi antar kidung.

H. Analisis Pengaruh Jumlah Kelas Terhadap Akurasi

Peningkatan akurasi pada skenario 5 kelas menunjukkan bahwa algoritma KNN bekerja lebih efektif ketika ruang fitur tidak terlalu padat atau tumpang tindih antar kelas. Pada dataset dengan 8 kelas, beberapa jenis kidung memiliki pola frekuensi dan amplitudo yang saling menyerupai sehingga menyebabkan overlap pada ruang fitur MFCC. Kondisi ini mengakibatkan sistem kesulitan menentukan jarak terdekat yang benar antara data uji dan data latih.

Sebaliknya, pada dataset dengan 5 kelas, variasi antar kelas lebih jelas dan terpisah, sehingga sistem dapat mengelompokkan data dengan lebih akurat. Hal ini juga sejalan dengan karakteristik algoritma KNN yang performanya sangat bergantung pada jarak antar data dan distribusi kelas dalam ruang fitur. Untuk memperjelas perbedaan performa antar skenario, grafik perbandingan tingkat akurasi ditampilkan pada Gambar 3.



Gambar 3 : Grafik Perbandingan Akurasi Sistem antara 8 Kelas dan 5 Kelas

Grafik tersebut memperlihatkan peningkatan performa sistem setelah jumlah kelas dikurangi. Dengan demikian, dapat disimpulkan bahwa semakin sedikit jumlah kelas yang diuji,

semakin baik tingkat akurasi yang diperoleh. Namun, untuk menjaga validitas sistem dalam kondisi nyata, jumlah kelas yang lebih banyak tetap perlu diuji agar sistem dapat dioptimalkan terhadap variasi kidung yang lebih kompleks.

Berdasarkan hasil perbandingan ini, dapat disimpulkan bahwa metode MFCC dan KNN mampu memberikan performa klasifikasi yang cukup baik pada data suara kidung Dewa Yadnya. Akan tetapi, performa sistem masih bergantung pada jumlah kelas dan tingkat kemiripan karakteristik antar kidung.

I. Analisis Hasil Pengujian Sistem

Penelitian ini dilakukan dengan dua skenario pengujian untuk mengetahui pengaruh jumlah kelas terhadap kinerja sistem klasifikasi. Pada skenario pertama (8 kelas), sistem menghasilkan akurasi sebesar 65,17%, sedangkan pada skenario kedua (5 kelas), akurasi meningkat menjadi 81,25%.

Perbedaan hasil tersebut menunjukkan bahwa jumlah kelas memiliki dampak signifikan terhadap performa sistem. Semakin banyak jumlah kelas yang diuji, kompleksitas pengenalan meningkat karena pola spektral antar kelas menjadi semakin mirip. Sebaliknya, pada dataset dengan 5 kelas, sistem lebih mudah membedakan pola karakteristik suara, karena ruang fitur MFCC yang dihasilkan memiliki jarak antarkelas yang lebih jelas.

Hasil ini menunjukkan bahwa fitur MFCC berhasil merepresentasikan karakteristik utama dari suara kidung, seperti intensitas dan frekuensi. Namun, kemampuan sistem untuk memisahkan antar kelas sangat bergantung pada kualitas data, jumlah kelas, dan parameter K pada algoritma KNN.

J. Pengaruh Jumlah Kelas Terhadap Akurasi

Jumlah kelas terbukti menjadi salah satu faktor yang paling berpengaruh dalam hasil klasifikasi. Pada penelitian ini, ketika sistem diuji dengan 8 kelas, terjadi penurunan akurasi hingga 16,08% dibandingkan dengan skenario 5 kelas. Hal ini disebabkan oleh overlapping antar kelas dalam ruang fitur MFCC, di mana beberapa kidung memiliki struktur nada dan intonasi yang mirip.

KNN bekerja berdasarkan kedekatan jarak antar data, sehingga jika dua kelas memiliki pola spektral yang mirip, sistem akan kesulitan menentukan batas yang jelas. Selain itu, karena jumlah data per kelas terbatas (10 file audio per kelas), variasi antar kelas belum cukup mewakili seluruh kemungkinan pola suara, yang menyebabkan model kurang stabil pada jumlah kelas yang lebih banyak.

K. Implikasi Hasil Penelitian

Hasil klasifikasi yang mencapai 80% akurasi pada dataset 5 kelas menunjukkan bahwa sistem mampu mengenali jenis kidung secara cukup akurat. Implikasinya, sistem ini dapat dikembangkan lebih lanjut sebagai alat bantu digital untuk mendukung pelestarian budaya Bali, seperti:

- Aplikasi pembelajaran mekidung berbasis suara
- Sistem arsip digital untuk dokumentasi kidung Dewa Yadnya

- Penggunaan teknologi AI untuk mendukung pelatihan dan validasi vokal pesanthi.

Namun demikian, hasil penelitian juga menunjukkan perlunya peningkatan dari sisi jumlah data dan variasi rekaman.

V. KESIMPULAN

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, dapat disimpulkan bahwa tujuan penelitian telah tercapai dengan rincian sebagai berikut:

- Ekstraksi ciri khas akustik menggunakan metode MFCC telah berhasil dilakukan. Proses ekstraksi ciri melalui tahapan *pre-emphasis*, *framing*, *windowing*, *fast Fourier transform (FFT)*, *filterbank*, dan *discrete cosine transform (DCT)* berhasil menghasilkan representasi numerik dari sinyal suara kidung Dewa Yadnya. Fitur MFCC mampu menggambarkan karakteristik utama sinyal audio berupa intensitas, frekuensi, dan pola harmonik, sehingga setiap file suara memiliki bentuk fitur yang berbeda sesuai dengan karakteristik kidung masing-masing.
- Pengukuran tingkat akurasi metode KNN menunjukkan hasil yang baik dan sesuai dengan ekspektasi. Hasil pengujian menunjukkan bahwa sistem klasifikasi dengan algoritma K-Nearest Neighbor (KNN) mampu mengenali jenis-jenis kidung berdasarkan fitur hasil ekstraksi MFCC dengan tingkat akurasi yang cukup tinggi. Pada dataset dengan 8 kelas kidung, akurasi yang diperoleh sebesar 66%, sedangkan pada dataset dengan 5 kelas kidung, akurasi meningkat menjadi 80%. Nilai K = 1 dan K = 2 menghasilkan performa terbaik pada kedua skenario, menunjukkan bahwa sistem bekerja optimal ketika mempertimbangkan tetangga terdekat dalam menentukan kelas suara.

Penerapan teknologi pengenalan suara berbasis MFCC dan KNN berpotensi mendukung pelestarian kidung Dewa Yadnya secara digital. Hasil penelitian ini menunjukkan bahwa sistem yang dikembangkan mampu mengenali pola akustik kidung Dewa Yadnya dengan cukup akurat, sehingga dapat dijadikan sebagai dasar dalam pengembangan sistem digitalisasi kidung. Teknologi ini berpotensi dimanfaatkan sebagai alat bantu pembelajaran, dokumentasi, dan pengarsipan kidung tradisional Bali, sehingga mendukung pelestarian budaya melalui pendekatan teknologi informasi.

REFERENSI

- [1] I. W. Suardiana, "Kesusastraan Bali Purwa," *Diakses Pada Tanggal*, 2020, [Online]. Available: https://simdos.unud.ac.id/uploads/file_penunjang_dir/ca313409fa2d6d9a429b2b664cf4d6ca.pdf.
- [2] Amri, "Komunikasi Dalam Menunjang Terwujudnya Makassar Sebagai 'Smart City,'" *J. Komun. KAREBA*, vol. 5, no. 2, pp. 431–445, 2016.
- [3] Z. D. Rusnalasari and U. N. Surabaya, "LPC," no. 3, pp. 168–178, 2025.
- [4] M. Hardiyanti and Y. Victor Rondonuwu, "Deteksi Suara Suling Sunda Menggunakan Metode Key-Nearest Neighbor," *Techno.Com*, vol. 23, no. 2, pp. 338–349, 2024, doi: 10.62411/tc.v23i2.9817.
- [5] F. Fadlila Surenggana, A. Aranta, and F. Bimantoro, "KLASIFIKASI MOOD MUSIK MENGGUNAKAN K-NEAREST NEIGHBOR

DENGAN MEL FREQUENCY CEPSTRAL COEFFICIENTS (Mood Music Classification using K-Nearest Neighbor with Mel Frequency Cepstral Coefficients)," *J. Teknol. Informasi, Komput. dan Apl.*, vol. 4, no. 2, pp. 263–276, 2023, [Online]. Available: <http://jtika.if.unram.ac.id/index.php/JTIKA/>.

- [6] F. R. K. Andre Julio Sumurung Marbun, Heriyanto, "Implementation of Mel-Frequency Cepstral Coefficient as Feature Extraction Method On Speech Audio Data," vol. 21, no. 3, pp. 260–270, 2024, doi: 10.31515/telematika.v21i3.12339.
- [7] I. M. Ade Prayoga, G. Indrawan, and D. G. Hendra Divayana, "Pengelompokan Laras Suara Berdasarkan Papatutan Atau Pathet Gamelan Bali Menggunakan Klasifikasi K-Nearest Neighbor Dan Support Vector Machine," *Technomedia J.*, vol. 8, no. 2SP, pp. 151–161, 2023, doi: 10.33050/tmj.v8i2sp.2011.
- [8] F. D. Adhinata and N. G. Ramadhan, "Review: Metode-Metode Ekstraksi Ciri dan Klasifikasi Identifikasi Pembicara," *J. Media Inform. Budidarma*, vol. 6, no. 1, p. 303, 2022, doi: 10.30865/mib.v6i1.3469.
- [9] M. N. Rabbani, "Mel-Frequency Cepstral Coefficient (MFCC) Implementation of Voice Recognition Based Key Using Mel Frequency Cepstral Coefficient (MFCC)," vol. 3, no. 3, pp. 3998–4007, 2016.
- [10] S. Y. Yehezkiel and Y. Suyanto, "Music Genre Identification Using SVM and MFCC Feature Extraction," *IJEIS (Indonesian J. Electron. Instrum. Syst.)*, vol. 12, no. 2, p. 115, 2022, doi: 10.22146/ijeis.70898.
- [11] A. Fajri Ryamizard, D. Bambang Hidayat, and S. SaidahST, "Deteksi Nada Tunggal Alat Musik Kecapi Bugis Makassar Menggunakan Metode Mel Frequency Cepstral Coefficient (Mfcc) Dan Klasifikasi K-Nearest Neighbour (Knn) Detection Single Tone of Bugis Makassar Music Instrument Using Mel Frequency Cepstral (Mfcc) Coeff," vol. 5, no. 3, pp. 4715–4721, 2018.
- [12] P. S. Informatika et al., "IMPLEMENTASI METODE MEL-FREQUENCY CEPSTRAL COEFFICIENT DAN," vol. 5, no. 1, pp. 65–71, 2022.
- [13] K. A. P. Kardiya and P. A. S. Santika, "Teknik Machine Learning dengan Metode SVM untuk Deteksi Anomali pada Kendala Jaringan FTTH," *Maj. Ilm. Teknol. Elektro*, vol. 24, no. 1, pp. 71–78, 2025, doi: 10.24843/mite.205.v24i01.p07.
- [14] D. M. S. Laksmi and I. W. Sudirana, "Kidung: Integral and Structured Parts in the Implementation of Balinese Hindu Religious ceremonies," *Malaysian J. Music*, vol. 12, no. 2, pp. 18–34, 2023, doi: 10.37134/MJM.VOL12.2.2.2023.
- [15] I. N. D. Putra and I. A. L. Sari, "Revitalisasi Tembang Teks Sastra Bali Tradisional dalam Ranah Ritual dan Digital," *Atavisme*, vol. 22, no. 1, pp. 32–46, 2019, doi: 10.24257/atavisme.v22i1.541.32-46.
- [16] R. A. N. Diaz, N. L. G. P. Suwirmayanti, and K. Budiarta, "Perbandingan Kualitas Pengenalan Suara Untuk Ekstraksi Fitur Menggunakan Mfcc Dan Spectral," *Naratif J. Nas. Riset, Apl. dan Tek. Inform.*, vol. 6, no. 1, pp. 58–63, 2024, doi: 10.53580/naratif.v6i1.281.
- [17] A. R. Nurjannah, E. S. Maydiana, and P. Kasih, "Pengenalan Suara Dzikir Menggunakan Ekstraksi Fitur MFCC dan Support Vector Machine," vol. 5, pp. 515–521, 2026.
- [18] E. Rejaibi, A. Komaty, F. Meriaudeau, S. Agrebi, and A. Othmani, "MFCC-based Recurrent Neural Network for automatic clinical depression recognition and assessment from speech," *Biomed. Signal Process. Control*, vol. 71, pp. 1–14, 2022, doi: 10.1016/j.bspc.2021.103107.
- [19] Z. K. Abdul and A. K. Al-Talabani, "Mel Frequency Cepstral Coefficient and its Applications: A Review," *IEEE Access*, vol. 10, no. October, pp. 122136–122158, 2022, doi: 10.1109/ACCESS.2022.3223444.
- [20] L. Rahma, H. Syaputra, A. H. Mirza, and S. D. Purnamasari, "Objek Deteksi Makanan Khas Palembang Menggunakan Algoritma YOLO (You Only Look Once)," *J. Nas. Ilmu Komput.*, vol. 2, no. 3, pp. 213–232, 2021, doi: 10.47747/jurnalnik.v2i3.534.
- [21] H. Rafliansyah, B. Rahmat, and C. A. Putra, "Klasifikasi Suara Instrumen Musik Tiup Menggunakan Metode Convolutional Neural Network," no. 4, 2024.
- [22] P. A. T. Santosa, A. Andang, and F. M. S. Nursuwars, "Deteksi Adaptif Titik Kunci Sinyal Photoplethysmography (PPG) dengan Pemodelan Gradien untuk Identifikasi Pola Fisiologis," *Maj. Ilm. Teknol. Elektro*, vol. 24, no. 1, pp. 51–60, 2025, doi: 10.24843/mite.205.v24i01.p05.
- [23] I. H. Kusuma and N. Cahyono, "Analisis Sentimen Masyarakat Terhadap Penggunaan E-Commerce Menggunakan Algoritma K-Nearest Neighbor," *J. Inform. J. Pengemb. IT*, vol. 8, no. 3, pp. 302–307, 2023, doi:



- 10.30591/jpit.v8i3.5734.
- [24] A. N. Nan and D. Juniati, "Klasifikasi Jenis Jangkrik Berdasarkan Suara Menggunakan Dimensi Fraktal Metode Higuchi Dan K-Nearest Neighbor (Knn)," *MATHunesa J. Ilm. Mat.*, vol. 10, no. 1, pp. 199–207, 2022, doi: 10.26740/mathunesa.v10n1.p199-207.
- [25] I. G. Harsemadi, "Perbandingan Kinerja Algoritma K-NN dan SVM dalam Sistem Klasifikasi Genre Musik Gamelan Bali," *INFORMATICS Educ. Prof. J. Informatics*, vol. 8, no. 1, p. 1, 2023, doi: 10.51211/itbi.v8i1.2417.