



## *Implementation of Machine Learning Algorithm for Environmental Sound Classification*

### **Implementasi Algoritma *Machine Learning* untuk Klasifikasi Suara Lingkungan**

Ari Wibowo<sup>1\*</sup>, Auliya Rahman Isnain<sup>2</sup>

<sup>1,2</sup>Fakultas Teknik dan Ilmu Komputer, Universitas Teknokrat Indonesia, Indonesia

E-Mail: <sup>1</sup>ariwibowo4306@gmail.com, <sup>2</sup>auliyarahman@teknokrat.ac.id

Received Oct 14th 2024; Revised Feb 16th 2025; Accepted Feb 23th 2025; Available Online Mar 21th 2025, Published Jan 21th 2025

Corresponding Author: Ari Wibowo

Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

#### **Abstract**

*Environmental sound plays a significant role in determining the quality of human life and the balance of ecosystems. With increasing urbanization and climate change, monitoring environmental sounds is crucial. This research implements Machine Learning algorithms to classify environmental sounds using the ESC-50 dataset. Features such as Mel-Frequency Cepstral Coefficients (MFCCs) and Chroma are used for feature extraction. After pre-processing the data, modeling was performed with various algorithms, including KNeighbors Classifier, Random Forest Classifier, and Extra Tree Classifier, which were then selected for hyperparameter tuning. With the optimal parameters, training on the selected model was performed and tested on the test dataset. The results show that the KNeighbors Classifier has the highest accuracy of 63%. This study contributes to developing environmental sound monitoring technology and opens up prospects for application in more efficient city management. Further studies are recommended for the exploration of more specific sound features, the use of deep learning techniques, and the use of wider datasets for more advanced solutions in understanding and managing environmental sound globally.*

*Keyword: Algorithm, Classification, Environmental Sound, Machine Learning, Sound*

#### **Abstrak**

Suara lingkungan memiliki peran signifikan dalam menentukan kualitas hidup manusia dan keseimbangan ekosistem. Dengan meningkatnya urbanisasi dan perubahan iklim, pemantauan suara lingkungan menjadi krusial. Penelitian ini mengimplementasikan algoritma *Machine Learning* untuk mengklasifikasikan suara lingkungan menggunakan dataset ESC-50. Fitur-fitur seperti *Mel-Frequency Cepstral Coefficients* (MFCCs) dan *Chroma* digunakan untuk ekstraksi ciri. Setelah pra-pemrosesan data, dilakukan pemodelan dengan berbagai algoritma, termasuk *KNeighbors Classifier*, *Random Forest Classifier*, dan *Extra Tree Classifier*, yang kemudian dipilih untuk *tuning hyperparameter*. Dengan parameter optimal, dilakukan *training* pada model terpilih dan diuji pada dataset uji. Hasil menunjukkan *KNeighbors Classifier* memiliki akurasi tertinggi sebesar 63%. Studi ini memberikan kontribusi pada pengembangan teknologi pemantauan suara lingkungan dan membuka prospek penerapan dalam manajemen kota yang lebih efisien. Studi lanjutan disarankan untuk eksplorasi fitur-fitur suara yang lebih spesifik, penggunaan teknik *deep learning*, dan penggunaan dataset yang lebih luas untuk solusi yang lebih canggih dalam pemahaman dan manajemen suara lingkungan secara global.

Kata Kunci: Algoritma, Klasifikasi, *Machine Learning*, Suara, Suara Lingkungan

#### **1. PENDAHULUAN**

Suara lingkungan berperan penting dalam menentukan kualitas hidup manusia dan keseimbangan ekosistem. Aktivitas manusia yang meningkat, urbanisasi, dan perubahan iklim telah memperbesar tingkat kebisingan dan variasi suara di lingkungan [1], sehingga pemantauan, identifikasi, dan pengelolaan suara menjadi semakin penting. Memahami sumber dan komposisi suara lingkungan diperlukan untuk menjaga kualitas lingkungan dan kesehatan masyarakat [2]. Tantangan utamanya adalah keragaman dan kompleksitas sumber suara, seperti dari kendaraan, industri, aktivitas manusia, dan alam [3]. Oleh karena itu, pendekatan canggih dibutuhkan untuk mengidentifikasi jenis suara dengan akurasi tinggi.



Algoritma *Machine Learning* (ML) menjadi solusi inovatif untuk mengatasi kompleksitas klasifikasi suara lingkungan. Permasalahan utama yang dihadapi dalam pengelolaan suara lingkungan adalah kesulitan dalam membedakan antara berbagai jenis suara dengan akurat, mengingat keragaman sumber suara yang ada. Dengan kemampuan ML dalam mengenali pola dari data, algoritma ini dapat secara otomatis mengklasifikasikan suara ke dalam kategori yang tepat, meningkatkan akurasi pemantauan suara dan membantu dalam pengambilan keputusan dalam pengelolaan suara lingkungan [4]. Tujuan penerapan ML dalam penelitian ini adalah untuk mengatasi tantangan dalam klasifikasi suara lingkungan yang sangat bervariasi. Penggunaan algoritma ML diharapkan dapat meningkatkan efisiensi dalam identifikasi sumber suara yang signifikan, mendukung perencanaan kota yang lebih baik, dan memperkuat upaya mitigasi dampak lingkungan. Teknologi ini juga memungkinkan analisis data yang lebih cepat dan respons yang lebih tanggap terhadap perubahan kondisi, yang membuka peluang solusi inovatif dalam pengelolaan lingkungan.

Dalam penelitian ini, berbagai algoritma ML digunakan untuk klasifikasi suara lingkungan dengan tujuan memilih model yang paling efektif dalam mengidentifikasi dan mengklasifikasikan suara dari berbagai sumber. Beberapa algoritma yang diterapkan, seperti *Support Vector Classification* (SVC), *Extra Tree Classifier*, *Linear Discriminant Analysis* (LDA), *Decision Tree Classifier*, *K-Neighbors Classifier* (K-NN), *Random Forest Classifier*, *MLP Classifier*, *AdaBoost Classifier*, Nu SVC, *Gaussian NB*, *Quadratic Discriminant Analysis* (QDA), *Logistic Regression*, *XGB Classifier*, *Bernoulli NB*, dan *Multinomial NB*, dipilih berdasarkan kekuatan mereka dalam menangani masalah klasifikasi dengan dataset yang besar dan beragam. SVC dan Nu SVC, misalnya, sering digunakan dalam masalah klasifikasi yang melibatkan data dengan margin pemisah yang jelas dan dapat bekerja sangat baik dengan data non-linear. *Decision Tree Classifier* dan *Random Forest Classifier*, di sisi lain, terkenal dengan kemampuannya untuk menangani data dengan fitur yang saling bergantung dan memberikan interpretasi model yang jelas. K-NN adalah algoritma yang bergantung pada kedekatan data, yang cocok untuk masalah yang memiliki distribusi data lokal yang signifikan. *MLP Classifier*, sebagai model jaringan saraf, menawarkan potensi yang besar dalam menangani data yang sangat kompleks dan non-linear, sedangkan *XGB Classifier* adalah algoritma *boosting* yang terbukti sangat efektif dalam meningkatkan akurasi model pada dataset besar. Algoritma lain seperti *Logistic Regression* dan *GaussianNB* juga dipilih untuk perbandingan karena kesederhanaannya dalam penerapan dan pemahaman. Pemilihan beberapa algoritma ini bertujuan untuk mengidentifikasi model yang paling efisien dan akurat dalam klasifikasi suara lingkungan, mengingat perbedaan dalam karakteristik suara yang perlu diklasifikasikan.

Beberapa penelitian terdahulu telah menggunakan berbagai algoritma *Machine Learning* untuk klasifikasi suara lingkungan, dengan hasil yang menunjukkan keberhasilan masing-masing algoritma dalam konteks yang berbeda. Penelitian yang menggunakan SVM dan SVC menunjukkan efektivitas algoritma ini dalam mengklasifikasikan suara lingkungan, terutama dalam kondisi dengan fitur yang tidak dapat dipisahkan secara linear [5]. *Random Forest Classifier* juga sering digunakan untuk masalah serupa karena kemampuannya dalam menangani data besar dan fitur yang beragam dengan akurasi yang cukup tinggi [6]. Di sisi lain, *Decision Tree Classifier* dan K-NN sering digunakan dalam penelitian yang menekankan pada interpretabilitas model dan kecepatan komputasi.

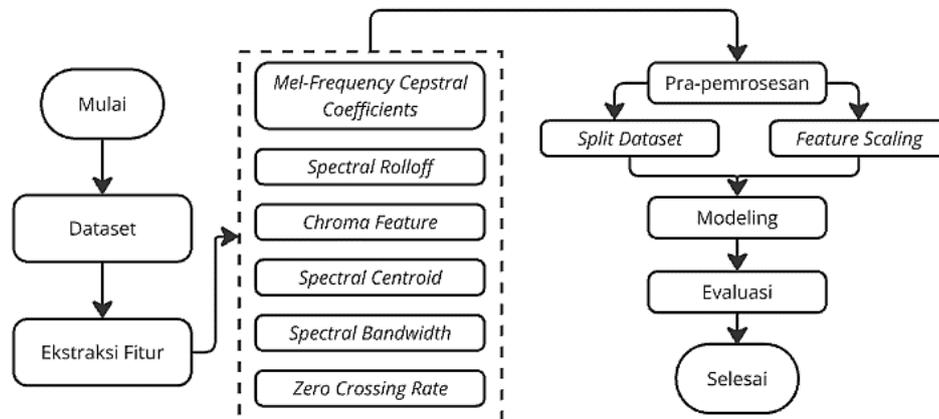
Namun, meskipun banyak penelitian yang berhasil menggunakan algoritma-algoritma tersebut, belum ada penelitian yang membandingkan algoritma-algoritma ini secara sistematis dalam konteks klasifikasi suara lingkungan yang beragam dan kompleks. Penelitian yang menggunakan LDA dan *GaussianNB* untuk suara dengan sedikit variabilitas, namun kurang efektif dalam klasifikasi suara yang lebih dinamis dan bervariasi [7]. Penelitian lain dengan menggunakan *XGBClassifier* menunjukkan keunggulannya dalam hal kecepatan dan akurasi, tetapi sering kali dibatasi oleh pengaturan parameter yang kompleks.

Perbedaan utama antara penelitian ini dengan penelitian terdahulu terletak pada pendekatan yang lebih komprehensif dalam membandingkan algoritma-algoritma ML dalam klasifikasi suara lingkungan yang sangat beragam. Penelitian ini tidak hanya membandingkan kinerja beberapa algoritma yang telah banyak diterapkan sebelumnya, tetapi juga memberikan analisis mendalam terhadap efektivitas setiap algoritma dalam menghadapi tantangan klasifikasi suara dari berbagai sumber (seperti kendaraan, alam, dan aktivitas manusia). Penelitian terdahulu sering kali terbatas pada penggunaan satu atau dua algoritma dalam kasus yang lebih terbatas, sedangkan penelitian ini akan mencakup berbagai algoritma dengan pendekatan eksperimen yang lebih terstruktur untuk mengetahui algoritma mana yang memberikan hasil terbaik dalam klasifikasi suara lingkungan. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam meningkatkan pemahaman tentang penerapan ML dalam pemantauan suara lingkungan yang lebih luas, serta menjadi dasar bagi penelitian lebih lanjut dalam bidang ini.

Oleh karena itu, penelitian ini akan memperbandingkan berbagai algoritma ML untuk menemukan kombinasi yang paling efektif dalam mengklasifikasikan suara lingkungan, termasuk fitur seperti MFCC dan *Chroma*, untuk mengatasi tantangan klasifikasi suara lingkungan dan memberikan pemahaman yang mendalam terhadap teknik dan model yang efektif.

## 2. METODE PENELITIAN

Dalam penelitian ini, Gambar 1 merupakan metode yang digunakan meliputi pemilihan *dataset*, ekstraksi fitur, pra-pemrosesan data, pemodelan, pelatihan model, dan evaluasi.



**Gambar 1.** Tahapan Penelitian

### 2.1 Dataset

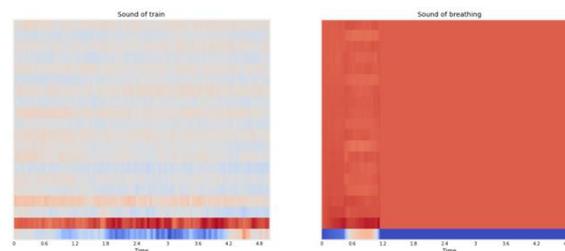
*Dataset* yang digunakan adalah ESC-50, yang diambil dari platform *Kaggle*. *Kaggle* adalah komunitas *online* yang berfokus pada *data science* dan ML. *Dataset* ESC-50 dikumpulkan oleh Marc Merouaux untuk mendukung penelitian pengenalan suara lingkungan. *Dataset* ini terdiri dari 2000 rekaman audio berdurasi 5 detik, dengan 50 file WAV yang diambil pada sampel 16KHz untuk 50 kelas berbeda. Setiap kelas memiliki 40 sampel suara berdurasi 5 detik, yang mencakup suara hewan, suara alam dan air, suara manusia non-verbal, suara interior/domestik, serta kebisingan luar ruang/ perkotaan.

### 2.2 Ekstraksi Fitur

Ekstraksi fitur dilakukan untuk mengubah data audio mentah menjadi representasi yang lebih ringkas dan bermakna, sehingga dapat diinterpretasikan oleh algoritma ML. Fitur-fitur ini membantu model dalam mengenali pola untuk klasifikasi.

#### 1. Mel-Frequency Cepstral Coefficients (MFCCs)

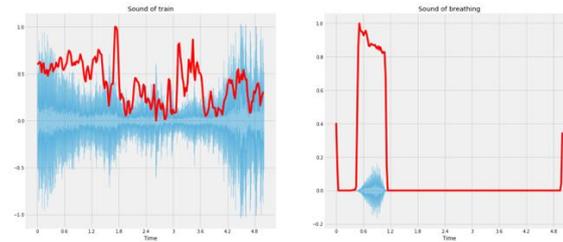
MFCCs adalah koefisien cepstral yang dihitung dari spektrum daya suara berdasarkan skala frekuensi Mel. MFCCs sering digunakan dalam klasifikasi suara karena kemampuannya untuk mengekstrak karakteristik penting dari suara, khususnya suara manusia [8]. MFCCs menyimpan informasi tentang bentuk spektrum frekuensi suara, yang membantu model mendeteksi pola unik dalam suara lingkungan. Visualisasi MFCCs untuk sampel data ditunjukkan pada Gambar 2.



**Gambar 2.** Visualisasi MFCCs

#### 2. Spectral Rolloff

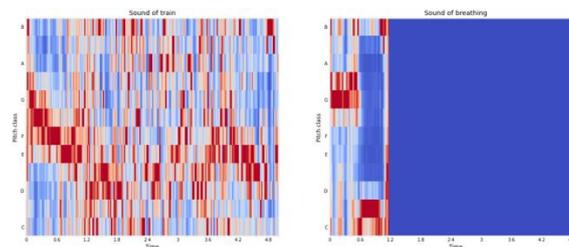
*Spectral Rolloff* menunjukkan frekuensi di mana sejumlah persentase tertentu dari energi suara terkonsentrasi di bawahnya [9]. Fitur ini membantu model memahami distribusi energi frekuensi dalam sebuah suara, yang dapat berguna untuk membedakan berbagai jenis suara. Visualisasi *Spectral Rolloff* untuk sampel data ditampilkan pada Gambar 3.



**Gambar 3.** Visualisasi *Spectral Rolloff*

**3. Chroma Feature**

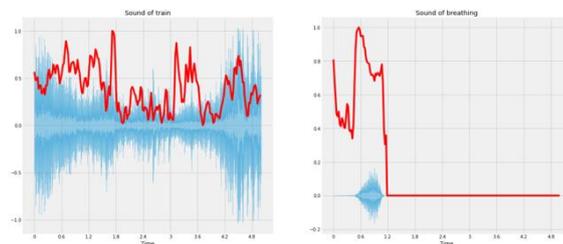
*Chroma Feature* berguna dalam menangkap distribusi energi frekuensi suara dalam skala *not music* [10]. Ini dapat membantu model mengidentifikasi pola harmonis dan karakteristik musikal dalam suara lingkungan, terutama jika suara tersebut memiliki unsur-unsur musikal. Visualisasi *Chroma Feature* pada sampel data dapat dilihat pada Gambar 4.



**Gambar 4.** Visualisasi *Chroma Feature*

**4. Spectral Centroid**

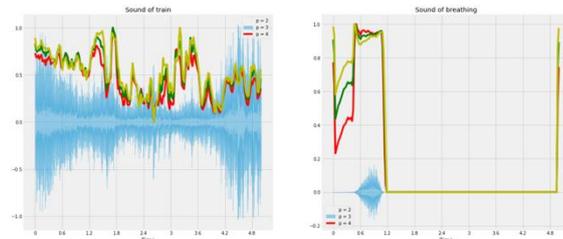
*Spectral Centroid* memberikan informasi tentang frekuensi pusat atau dominan dari suara [11]. Dalam konteks suara lingkungan, ini dapat membantu model mengklasifikasikan jenis suara berdasarkan karakteristik spektral pusatnya, seperti suara alam yang cenderung memiliki pusat frekuensi yang lebih rendah. Visualisasi *Spectral Centroid* pada sampel data dapat dilihat pada Gambar 5.



**Gambar 5.** Visualisasi *Spectral Centroid*

**5. Spectral Bandwidth**

*Spectral Bandwidth* memberikan informasi tentang lebar spektrum frekuensi suara [12]. Hal ini dapat membantu model membedakan antara suara yang luas dan beragam frekuensinya dengan suara yang lebih terfokus pada frekuensi tertentu. Visualisasi *Spectral Bandwidth* secara umum pada sampel data dapat dilihat pada gambar 6.



**Gambar 6.** Visualisasi *Spectral Bandwidth*

### 2.3 Pra-pemrosesan

Praproses data diterapkan untuk memastikan kekonsistenan dan kualitas data sebelum memasukkannya ke dalam model. Ini melibatkan *splitting* data dan fitur *scaling*.

#### 1. *Split Dataset*

Pertama-tama, *dataset* ESC-50 dibagi menjadi dua bagian utama: set pelatihan (*training set*) dan set pengujian (*test set*). Dalam penelitian ini, pembagian dataset dilakukan dengan menggunakan ukuran set pengujian sebesar 0.05 atau 5% dari total dataset. Pendekatan ini bertujuan untuk memastikan bahwa model dilatih pada sebagian besar data tetapi juga diuji pada subset yang cukup besar untuk mengukur kinerjanya [13]. Sehingga untuk *training set* mendapatkan 1900 data dan *testing set* 100 data dari keseluruhan data.

#### 2. *Feature Scaling*

Dalam pembelajaran mesin, penskalaan fitur adalah teknik yang digunakan untuk menstandarisasi rentang variabel independen atau fitur data. Karena rentang nilai data mentah sangat bervariasi, pada beberapa algoritma pembelajaran mesin, fungsi tujuan tidak akan berfungsi dengan baik tanpa normalisasi [14]. Dalam penelitian ini, Min-Max Scaling digunakan untuk memastikan bahwa nilai-nilai fitur berada dalam rentang yang seragam yaitu 0 sampai 1 [15]. Proses Min-Max *Scaling* digambarkan pada persamaan (1).

$$x' = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad (1)$$

### 2.4 Modeling

Pada tahap ini, berbagai algoritma klasifikasi *Machine Learning* digunakan untuk mengklasifikasikan suara lingkungan diantaranya adalah *SVC*, *Extra Tree Classifier*, *Linear Discriminant Analysis*, *Decision Tree Classifier*, *K-NN*, *Random Forest Classifier*, *MLPClassifier*, *AdaBoostClassifier*, *NuSVC*, *GaussianNB*, *QuadraticDiscriminantAnalysis*, *LogisticRegression*, *XGBClassifier*, *BernoulliNB*, dan *MultinomialNB*. Setiap *classifier* memiliki parameter *default* atau telah diatur sebelumnya untuk eksperimen awal. Langkah ini bertujuan untuk membandingkan performa relatif dari berbagai algoritma pada data.

*Cross-validation* digunakan untuk mengevaluasi kinerja setiap *classifier*. Proses ini membagi *dataset* menjadi beberapa subset (*fold*), dan model dilatih dan dievaluasi beberapa kali untuk mengurangi dampak variabilitas pada satu pembagian dataset tertentu. Metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score* digunakan untuk mengevaluasi performa setiap *classifier* [16]. Dilakukan *cross-validation* untuk mengevaluasi kinerja setiap *classifier*. Hasil dari *Cross-validation* kemudian diambil *classifier* untuk di-*tuning*. Melalui proses *tuning* parameter, parameter optimal untuk model yang dipilih dicari dengan menggunakan *GridSearchCV* untuk mengidentifikasi kombinasi parameter terbaik yang meningkatkan kinerja model.

### 2.5 Evaluasi

Evaluasi model dilakukan dengan menggunakan metrik akurasi. Pengujian model dilakukan pada dataset *test* yang belum pernah dilihat sebelumnya untuk mengukur kinerja generalisasi model. Support Vector Classification (SVC) Support Vector Classification (SVC) adalah salah satu algoritma yang populer dalam klasifikasi karena kemampuannya untuk menangani data non-linear dengan menggunakan kernel trick. SVC bekerja dengan mencari hyperplane terbaik yang memisahkan kelas-kelas data dengan margin terbesar. Beberapa penelitian telah menunjukkan efektivitas SVC dalam klasifikasi data suara dengan tingkat akurasi yang tinggi [17]. Dalam penelitian suara lingkungan, SVC mampu menangani kompleksitas suara yang memiliki variasi spektral.

### 2.6 Literature Review Algoritma

*Extra Tree Classifier* adalah model ensemble berbasis pohon keputusan yang membangun sejumlah pohon keputusan secara acak dan kemudian mengambil mayoritas prediksi dari pohon-pohon tersebut. Algoritma ini dapat bekerja dengan baik dalam mengatasi data yang memiliki banyak fitur dengan tingkat akurasi yang cukup tinggi [17]. Penggunaan *Extra Tree Classifier* dalam suara lingkungan membantu dalam klasifikasi suara yang memiliki banyak fitur spektral. LDA adalah metode klasifikasi yang digunakan untuk menemukan kombinasi linear dari fitur yang memisahkan dua atau lebih kelas data. LDA efektif untuk masalah klasifikasi dengan dimensi data yang tinggi dan jumlah data yang terbatas [18]. Dalam penelitian suara, LDA dapat digunakan untuk membedakan suara yang memiliki distribusi data yang berbeda. Decision Tree Classifier adalah algoritma yang membangun model berbentuk pohon keputusan untuk membuat keputusan klasifikasi berdasarkan nilai atribut yang berbeda. Keunggulan utama dari Decision Tree Classifier adalah interpretabilitasnya, yang memungkinkan pemahaman tentang keputusan yang diambil oleh model [19]. Algoritma ini sering digunakan dalam aplikasi suara karena kemudahan dalam analisis dan prediksi. K-NN adalah algoritma yang mengklasifikasikan data berdasarkan kedekatannya dengan data lain dalam ruang fitur.

K-NN digunakan untuk masalah klasifikasi dengan data yang memiliki pola lokal yang kuat, terbukti efektif dalam klasifikasi suara karena kesederhanaannya dalam mengklasifikasikan suara dengan kedekatan data [20].

*RandomForestClassifier* adalah *ensemble* dari pohon keputusan yang bekerja dengan cara menggabungkan hasil dari berbagai pohon keputusan untuk meningkatkan keakuratan dan mengurangi overfitting. Penelitian telah menunjukkan bahwa *Random Forest Classifier* sangat efektif dalam klasifikasi suara dengan banyak variasi dan fitur [21]. Algoritma ini sangat cocok untuk klasifikasi suara lingkungan yang melibatkan banyak kategori suara. *MLPClassifier* adalah model jaringan saraf tiruan yang menggunakan beberapa lapisan tersembunyi untuk belajar dari data dan mengklasifikasikan input ke dalam kategori tertentu. *MLPClassifier* sangat efektif dalam menangani masalah klasifikasi dengan data yang sangat kompleks dan *non-linear* [22]. Dalam penelitian suara, *MLPClassifier* membantu mengidentifikasi pola suara yang lebih rumit dan kompleks. *AdaBoostClassifier* adalah algoritma *ensemble* yang bekerja dengan cara menggabungkan beberapa model klasifikasi lemah menjadi satu model yang kuat. *AdaBoost* meningkatkan akurasi model dengan memberikan bobot lebih pada data yang sulit diklasifikasikan [23]. Penggunaan *AdaBoost* dalam penelitian suara terbukti efektif dalam meningkatkan akurasi klasifikasi suara. *NuSVC* adalah variasi dari SVM yang menggunakan parameter *nu* untuk mengontrol margin dan jumlah kesalahan. *NuSVC* dapat bekerja dengan baik pada data dengan distribusi yang tidak sepenuhnya linear dan banyak digunakan dalam masalah klasifikasi dengan data besar [24]. Dalam penelitian suara, *NuSVC* telah digunakan untuk klasifikasi suara dengan tingkat akurasi yang tinggi. *GaussianNB* adalah algoritma probabilistik yang mengasumsikan bahwa setiap fitur mengikuti distribusi Gaussian. *GaussianNB* sering digunakan dalam klasifikasi suara karena kesederhanaannya dan kemampuannya untuk menangani data yang memiliki distribusi normal [25].

QDA adalah metode klasifikasi yang memodelkan setiap kelas dengan distribusi Gaussian dan membedakan kelas-kelas tersebut menggunakan fungsi diskriminan kuadrat. QDA lebih fleksibel daripada LDA dan dapat menangani kasus di mana kelas-kelas data memiliki kovarians yang berbeda [26]. *Logistic Regression* adalah model yang digunakan untuk klasifikasi biner dan mengestimasi probabilitas kelas berdasarkan fungsi logistik. Meskipun sederhana, *Logistic Regression* efektif untuk data dengan hubungan linear antara fitur dan kelas [27]. *XGBClassifier* adalah klasifikasi berbasis teknik *boosting* yang menggunakan pendekatan *gradient boosting* untuk meningkatkan kinerja model. *XGBClassifier* dikenal karena akurasi dan kecepatan komputasinya dalam menangani dataset besar dan kompleks [28]. *BernoulliNB* adalah variasi dari Naive Bayes yang mengasumsikan bahwa fitur mengikuti distribusi Bernoulli. Algoritma ini cocok untuk klasifikasi dengan data yang memiliki fitur biner [29]. *MultinomialNB* adalah varian Naive Bayes yang digunakan untuk klasifikasi teks atau data dengan distribusi multinomial. Dalam klasifikasi suara, *MultinomialNB* digunakan untuk menangani data dengan beberapa kategori atau kelas suara yang terpisah [30].

### 3. HASIL DAN PEMBAHASAN

Hasil eksperimen diperoleh dengan membandingkan kinerja beberapa algoritma klasifikasi.

#### 3.1. Hasil Cross-Validation

Performa berbagai algoritma dievaluasi menggunakan pendekatan *cross-validation*, di mana *dataset* dibagi menjadi beberapa *subset*, kemudian model dilatih dan diuji secara bergantian. Proses ini memberikan gambaran yang lebih akurat tentang kemampuan model dalam menggeneralisasi data yang belum pernah dilihat sebelumnya. Rata-rata skor akurasi tertinggi dari masing-masing algoritma pada data uji dapat dilihat pada Tabel 1.

**Tabel 1.** Hasil Cross Validation

No	Classifier	Skor Cross Validation
1	BernoulliNB	0.04
2	AdaBoost Classifier	0.06
3	Quadratic Discriminant Analysis	0.11
4	Decision Tree Classifier	0.20
5	Gaussian NB	0.24
6	Linear Discriminant Analysis	0.25
7	Support Vector Classification	0.33
8	Multinomial NB	0.35
9	XGBClassifier	0.41
10	Logistic Regression	0.43
11	MLP Classifier	0.47
12	NuSVC	0.48
13	K-NN	0.49
14	Extra Tree Classifier	0.50
15	Random Forest Classifier	0.50

### 3.2. Hyperparameter Tuning

Berdasarkan hasil *Cross Validation*, model dengan skor tertinggi dipilih untuk melakukan *tuning hyperparameter* guna memperoleh parameter pelatihan terbaik untuk *classifier* yang dipilih. Konfigurasi *tuning* dapat dilihat pada Tabel 2, sementara hasilnya ditampilkan pada Tabel 3.

**Tabel 2.** Konfigurasi *Hyperparameter Tuning*

No	Classifier	Parameter Tuning
1	Random Forest Classifier	n_estimators: [ 100, 200, 500]
2	Extra Tree Classifier	n_estimators: [ 100, 200, 500]
3	K-NN	n_neighbors: [1, 2, 4, 6, 8, 10]
4	NuSVC	nu: [0.1,0.3, 0.5, 0.7,0.9]

**Tabel 3.** Hasil *Hyperparameter Tuning*

No	Classifier	Best Parameter
1	Random Forest Classifier	500
2	Extra Tree Classifier	500
3	K-NN	1
4	NuSVC	0.3

Berdasarkan Tabel 2 untuk *Random Forest Classifier* dan *Extra Tree Classifier*, *hyperparameter* yang diatur adalah jumlah pohon keputusan (*n\_estimators*) dengan variasi nilai [100, 200, 500]. Hasil *tuning* mengindikasikan bahwa jumlah pohon optimal untuk kedua model adalah 500, yang menunjukkan bahwa peningkatan jumlah pohon memberikan dampak signifikan terhadap kinerja model. Pada K-NN, *hyperparameter* yang di-*tuning* adalah jumlah tetangga terdekat (*n\_neighbors*) dengan variasi nilai [1, 2, 4, 6, 8, 10]. Hasil *tuning* menunjukkan bahwa jumlah tetangga terbaik adalah 1, yang menandakan bahwa model lebih efektif dengan mempertimbangkan tetangga terdekat yang paling mirip. Selanjutnya, pada NuSVC, *hyperparameter* yang di-*tuning* adalah parameter nu dengan variasi nilai [0.1, 0.3, 0.5, 0.7, 0.9]. Hasil *tuning* menunjukkan bahwa nilai nu terbaik adalah 0.3, yang mencerminkan tingkat toleransi kesalahan yang optimal dalam model.

### 3.3. Hasil Training

Dengan parameter terbaik yang telah ditetapkan, proses pelatihan dilakukan pada setiap model, diikuti dengan evaluasi pada data uji untuk mengukur kinerja model. Hasilnya, *Random Forest Classifier* menunjukkan akurasi sempurna pada data pelatihan (100%). Namun, model ini mengalami *overfitting* pada data pengujian dengan akurasi hanya sebesar 55,00%. Selanjutnya, *Extra Trees Classifier* juga mencapai akurasi 100% pada data pelatihan, yang menunjukkan keyakinan tinggi pada prediksi kelas. Namun, mirip dengan *Random Forest Classifier*, model ini mengalami penurunan kinerja pada data pengujian (58,00%). K-NN menunjukkan kinerja yang cukup baik dengan akurasi 62,00% pada data pengujian. Meskipun akurasi pada data pelatihan juga sempurna, model ini dapat mempertahankan performa yang relatif tinggi pada data baru. Terakhir, *Classifier NuSVC* menunjukkan kinerja baik pada data pelatihan dengan akurasi mencapai 85,84%, serta *F1-score*, *precision*, dan *recall* yang tinggi. Namun, model ini juga menunjukkan *overfitting* pada data pengujian dengan akurasi hanya 46,00%, yang mencerminkan penurunan performa yang signifikan.

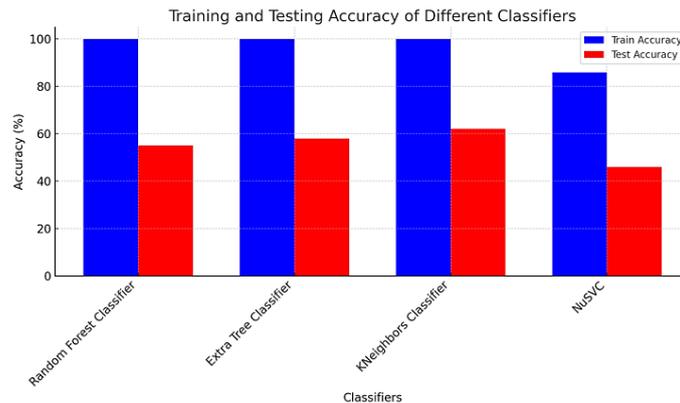
Adapun Tabel 4. Hasil *Training* hanya mencantumkan 4 algoritma utama yang dipilih berdasarkan hasil *cross-validation* yang paling menonjol atau yang menunjukkan variasi kinerja paling signifikan pada data pengujian. Algoritma lain yang tidak disertakan dalam tabel ini memiliki hasil yang serupa dalam hal akurasi pelatihan dan pengujian, atau tidak menunjukkan perbedaan signifikan dalam hal kinerja dibandingkan dengan model-model yang telah dipilih. Meskipun demikian, algoritma lain yang digunakan dalam penelitian ini tetap dianalisis, namun untuk tujuan presentasi yang lebih jelas dan fokus, hanya model-model dengan performa yang paling mencolok.

**Tabel 4.** Hasil Training

Classifier	Accuracy	
	Train	Test
Random Forest Classifier	100%	55%
Extra Tree Classifier	100%	58%
K-NN	100%	62%
NuSVC	85.84%	46.00%

Berdasarkan Tabel 4, Model K-NN menunjukkan kinerja terbaik dengan akurasi tertinggi sebesar 63%. Variasi akurasi di antara model-model tersebut mengindikasikan bahwa masing-masing model memiliki

kelebihan dan kekurangan dalam menangani dataset suara lingkungan. Visualisasi datanya dapat dilihat pada Gambar 7.



**Gambar 7.** Visualisasi Kinerja Hasil *Training*

Hasil yang diperoleh dari eksperimen menunjukkan bahwa meskipun beberapa algoritma, seperti *Random Forest* dan *Extra Trees*, menunjukkan akurasi pelatihan yang sempurna, kedua model tersebut mengalami *overfitting* yang signifikan pada data pengujian. *Overfitting* ini terjadi karena model terlalu baik mempelajari pola dari data pelatihan yang terbatas, namun tidak mampu menggeneralisasi dengan baik pada data yang tidak pernah dilihat sebelumnya. Hal ini mengindikasikan bahwa meskipun model memiliki kapasitas besar untuk belajar, pengaturan *hyperparameter* yang lebih baik diperlukan untuk meningkatkan kemampuannya dalam melakukan generalisasi. Dalam konteks klasifikasi suara lingkungan, fenomena ini dapat terjadi karena keberagaman sumber suara yang sangat tinggi, membuat model perlu lebih fleksibel dalam menangani data yang belum pernah ditemui.

Di sisi lain K-NN menunjukkan hasil yang lebih stabil dengan akurasi yang lebih tinggi pada data pengujian. Model ini berfungsi dengan baik karena pendekatan berbasis kedekatan data memungkinkan untuk mempertahankan performa yang lebih tinggi meskipun pada data yang bervariasi. Keberhasilan K-NN dalam menjaga kinerja yang baik pada data pengujian dapat dikaitkan dengan karakteristik suara lingkungan yang sering kali memiliki pola lokal yang jelas, seperti suara hewan atau kendaraan. Dalam konteks ini, kedekatan data (*neighborhood*) menjadi faktor yang sangat penting untuk menghasilkan klasifikasi yang akurat, terutama ketika data baru memiliki kesamaan yang erat dengan sampel pelatihan.

Penerapan teknologi ML dalam klasifikasi suara lingkungan memberikan keuntungan signifikan dalam efisiensi pemantauan suara, yang merupakan tantangan besar dalam urbanisasi dan perubahan iklim saat ini. Pemanfaatan fitur-fitur seperti MFCCs, *Spectral Rolloff*, dan *Chroma*, telah terbukti membantu dalam mengekstrak karakteristik penting dari suara, yang penting untuk mengidentifikasi sumber suara dengan lebih akurat. Hal ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa fitur-fitur spektral dapat menangkap informasi esensial untuk membedakan jenis suara dalam berbagai kondisi lingkungan [31]. Di samping itu, hasil dari eksperimen ini juga menegaskan bahwa teknologi ML dapat meningkatkan respons terhadap perubahan lingkungan secara real-time, memungkinkan perencanaan kota yang lebih baik serta upaya mitigasi dampak kebisingan yang lebih efektif.

Namun, meskipun hasil yang diperoleh cukup menjanjikan, terdapat beberapa tantangan yang masih harus diatasi dalam penerapan ML pada klasifikasi suara lingkungan. Salah satunya adalah keragaman sumber suara yang bisa mempengaruhi kinerja model. Misalnya, suara alam seperti suara hujan atau angin cenderung memiliki karakteristik yang sangat berbeda dengan suara kendaraan atau aktivitas manusia, yang dapat menyebabkan kesulitan bagi algoritma dalam membedakan jenis suara tersebut. Oleh karena itu, pengumpulan data yang lebih beragam dan representatif serta penggunaan model ensemble yang lebih canggih bisa menjadi langkah selanjutnya untuk meningkatkan akurasi klasifikasi dalam skenario dunia nyata.

#### 4. KESIMPULAN

Penelitian ini menunjukkan bahwa algoritma ML dapat diimplementasikan untuk klasifikasi suara lingkungan menggunakan dataset ESC-50, dengan model K-NN mencapai akurasi terbaik sebesar 63%. Penggunaan fitur seperti MFCCs, *Spectral Rolloff*, dan *Chroma Feature* terbukti efektif dalam klasifikasi. Hasil ini menunjukkan potensi algoritma ML untuk pemantauan dan identifikasi suara lingkungan, serta memberikan dasar bagi pengembangan solusi inovatif dalam manajemen lingkungan. Penerapan algoritma ini dapat diintegrasikan dalam sistem pemantauan lingkungan perkotaan, sementara studi lanjutan dapat meningkatkan akurasi klasifikasi dengan menganalisis fitur suara yang lebih spesifik untuk setiap kategori.

## REFERENSI

- [1] M. C. Kondo, J. M. Fluehr, T. McKeon, and C. C. Branas, "Urban green space and its impact on human health," Mar. 03, 2018, *MDPI*. doi: 10.3390/ijerph15030445.
- [2] W. Octovianus and R. Sugiarto, "KAJIAN SOUNDSCAPE SEBAGAI KRITIK TERHADAP PROPORSI DAN ELEMEN ARSITEKTURAL DI JALAN BRAGA, BANDUNG," *LANGKAU BETANG: JURNAL ARSITEKTUR*, vol. 9, no. 2, p. 156, Oct. 2022, doi: 10.26418/lantang.v9i2.53651.
- [3] H. P. Kunc and R. Schmidt, "The effects of anthropogenic noise on animals: A meta-analysis," *Biol Lett*, vol. 15, no. 11, Nov. 2019, doi: 10.1098/rsbl.2019.0649.
- [4] L. Yang, X. Liu, W. Zhu, L. Zhao, and G. C. Beroza, "Toward improved urban earthquake monitoring through deep-learning-based noise suppression," 2022. [Online]. Available: <https://www.science.org>
- [5] L. S. P. Annabel, S. P. G, and T. V, "Environmental Sound Classification Using 1-D and 2-D Convolutional Neural Networks," pp. 1242–1247, 2023, doi: 10.1109/iceca58529.2023.10395326.
- [6] H. A. Salman, A. Kalakech, and A. Steiti, "Random Forest Algorithm Overview," *Deleted Journal*, vol. 2024, pp. 69–79, 2024, doi: 10.58496/bjml/2024/007.
- [7] "Varying Coefficient Linear Discriminant Analysis for Dynamic Data," 2022, doi: 10.48550/arxiv.2203.06371.
- [8] J. Singh, "pyAudioProcessing: Audio Processing, Feature Extraction, and Machine Learning Modeling," 2022. [Online]. Available: <https://developers.google.com/learn/pathways/get-started-audio->
- [9] B. Ghani and S. Hallerberg, "A Randomized bag-of-birds Approach to Study Robustness of Automated Audio Based Bird Species Classification," 2021, doi: 10.20944/preprints202108.0277.v1.
- [10] N. N. W. N. Hashim, M. A. E. A. Ezzi, and M. D. Wilkes, "Mobile microphone robust acoustic feature identification using coefficient of variance," *Int J Speech Technol*, vol. 24, no. 4, pp. 1089–1100, Dec. 2021, doi: 10.1007/s10772-021-09877-1.
- [11] A. Anikin and N. Johansson, "Implicit associations between individual properties of color and sound," *Atten Percept Psychophys*, vol. 81, no. 3, pp. 764–777, Apr. 2019, doi: 10.3758/s13414-018-01639-7.
- [12] M. J. Grotevent *et al.*, "Integrated photodetectors for compact Fourier-transform waveguide spectrometers," *Nat Photonics*, vol. 17, no. 1, pp. 59–64, Jan. 2023, doi: 10.1038/s41566-022-01088-7.
- [13] N. Konda, R. Verma, and R. Jayaganthan, "Machine learning based predictions of fatigue crack growth rate of additively manufactured ti6al4v," *Metals (Basel)*, vol. 12, no. 1, Jan. 2022, doi: 10.3390/met12010050.
- [14] J. He and Z. Zeng, "Efficient Feature Selection via Joint Neural Network and Pruning," in *Frontiers in Artificial Intelligence and Applications*, IOS Press BV, 2022, pp. 138–145. doi: 10.3233/FAIA220019.
- [15] A. M. Elshewey, "hyOPTGB: An Efficient OPTUNA Hyperparameter Optimization Framework for Hepatitis C Virus (HCV) Disease Prediction in Egypt hyOPTGB: An Efficient OPTUNA Hyperparameter Optimization Framework for Hepatitis C Virus (HCV) Disease Prediction in Egypt," 2023, doi: 10.21203/rs.3.rs-2768795/v1.
- [16] A. Vabalas, E. Gowen, E. Poliakoff, and A. J. Casson, "Machine learning algorithm validation with a limited sample size," *PLoS One*, vol. 14, no. 11, Nov. 2019, doi: 10.1371/journal.pone.0224365.
- [17] G. Gayathri, P. Priyanka, B. Manjeera, K. Niharika, V. P. K. S, and V. K. K. Kolli, "An Extra Tree Classifier for prediction of End to End Customer Churn and Retention," pp. 1–6, 2024, doi: 10.1109/apcit62007.2024.10673618.
- [18] T.-T. Vo, U. J. Dang, and T. H. Nguyen, "Weighted Missing Linear Discriminant Analysis: An Explainable Approach for Classification with Missing Data," 2024, doi: 10.48550/arxiv.2407.00710.
- [19] M. Fleissner, M. Zarvandi, and D. Ghoshdastidar, "Decision Trees for Interpretable Clusters in Mixture Models and Deep Representations," 2024, doi: 10.48550/arxiv.2411.01576.
- [20] O. O. Kyrsanov and S. Krivenko, "Feature engineering for the implementation of machine learning in clinical data processing," *Infokomunikacijni tehnologiji ta elektronna inženieriã*, vol. 4, no. 2, pp. 162–171, 2024, doi: 10.23939/ict2024.02.162.
- [21] S. K. Safi and S. Gul, "An Enhanced Tree Ensemble for Classification in the Presence of Extreme Class Imbalance," *Mathematics*, 2024, doi: 10.3390/math12203243.
- [22] B. Ghasemkhani, K. F. Balbal, and D. Birant, "A New Predictive Method for Classification Tasks in Machine Learning: Multi-Class Multi-Label Logistic Model Tree (MMLMT)," *Mathematics*, vol. 12, no. 18, p. 2825, 2024, doi: 10.3390/math12182825.
- [23] H. Kaur, T. Kaur, V. Bhardwaj, and M. Kumar, "An ensemble deep learning model for classification of students as weak and strong learners via multiparametric analysis," *Deleted Journal*, vol. 6, no. 11, 2024, doi: 10.1007/s42452-024-06274-6.
- [24] H. Wang, "Development and validation of an Adaboost model for breast cancer classification," *Applied and Computational Engineering*, vol. 67, no. 1, pp. 107–114, 2024, doi: 10.54254/2755-2721/67/20240643.
- [25] C. Annamalai, "The Gaussian Integral for the Normal Distribution in Machine Learning," 2024, doi: 10.33774/coe-2024-p4j6k.

- [26] F. Guo, D. M. Zucker, K. I. Vaden, S. G. Curhan, J. R. Dubno, and M. Wang, "New Quadratic Discriminant Analysis Algorithms for Correlated Audiometric Data," *Stat Med*, 2024, doi: 10.1002/sim.10257.
- [27] A. Marakhimov, K. Khudaybergenov, Z. Muminov, and J. Kudaybergenov, "Logistic Regression with Multi-Connected Weights," *Journal of Computer Science*, vol. 20, no. 9, pp. 1051–1058, 2024, doi: 10.3844/jcssp.2024.1051.1058.
- [28] S. Hakkal and A. A. Lahcen, "XGBoost To Enhance Learner Performance Prediction," *Computers & Education: Artificial Intelligence*, vol. 7, p. 100254, 2024, doi: 10.1016/j.caeai.2024.100254.
- [29] F. C. Opone and C. Chesneau, "Study of the inverse continuous Bernoulli distribution," *Malaya journal of matematik*, vol. 12, no. 03, pp. 253–261, 2024, doi: 10.26637/mjm1203/003.
- [30] M. H. Zahri, A. S. Sunge, and A. T. Zy, "Analysis of Product Sales in the Application of Data Mining with Naive Bayes Classification," *Journal of Computer Networks, Architecture and High Performance Computing*, 2024, doi: 10.47709/cnahpc.v6i3.4255.
- [31] F. Artuso *et al.*, "Identifying optimal feature sets for acoustic signal classification in environmental noise measurements," *NOISE-CON ... proceedings*, 2024, doi: 10.3397/in\_2024\_3974.