

Perbandingan Metode Ensemble Learning Random Forest Dan Adaboost Pada Pengenalan Chord Instrumen Piano Dan Gitar

I Dewa Agung Adwitya Prawangsa, AAIN Eka Karyawati

Informatika, Universitas Udayana
Jl. Raya Kampus UNUD, Bukit Jimbaran, Kuta Selatan, Badung, Bali, Indonesia
prawangsa091@student.unud.ac.id
eka.karyawati@unud.ac.id

Abstract

This paper presents a comprehensive analysis of Random Forest and Adaboost algorithms for classifying music chords, focusing on feature extraction and model optimization. The distribution of original data, including audio signal lengths and class distributions, is examined, revealing consistent characteristics across major and minor datasets. Mel Frequency Cepstral Coefficients (MFCC) are extracted with predefined parameters, ensuring feature extraction consistency. Subsequent feature normalization and oversampling using SMOTE address class imbalances. Evaluation metrics, including accuracy, precision, recall, and F1-score, are employed to assess model performance. The results demonstrate Random Forest's superiority in accuracy, precision, and recall over Adaboost. Furthermore, employing RandomizedSearchCV optimization enhances both models' performance, with Random Forest achieving an accuracy of 0.86 and Adaboost attaining 0.80. Confusion matrices illustrate Random Forest's higher prediction accuracy for both positive and negative classes compared to Adaboost. These findings underscore the effectiveness of Random Forest in accurately classifying music chords and highlight the significance of hyperparameter optimization in enhancing classification model performance.

Keywords: Random Forest, Adaboost, Random Search, Confusion Matrix

1. Pendahuluan

Musik telah menjadi bagian tak terpisahkan dari kehidupan manusia selama berabad-abad, memberikan hiburan dan keindahan yang tak ternilai. Di era modern ini, perkembangan teknologi komputer dan kecerdasan buatan telah membuka peluang baru dalam pengenalan elemen-elemen musik secara otomatis, salah satunya adalah pengenalan Chord. Random forest merupakan metode pembelajaran terintegrasi penting berbasis bagging. Algoritma ensemble AdaBoost adalah algoritma iteratif berdasarkan multiple base learners dari jenis yang sama [1]. Penggunaan teknik ensemble learning seperti Random Forest dengan menggunakan Bootstrap Aggregating serta pemilihan acak untuk menghasilkan hasilnya [3] dan Adaboost yang berfokus pada pembangunan model yang lemah [4] telah menjadi sorotan dalam pengenalan pola suara, termasuk dalam konteks pengenalan Chord pada instrumen musik seperti piano dan gitar. Meskipun demikian, penelitian yang secara spesifik membandingkan kinerja kedua metode tersebut dalam pengenalan Chord masih terbatas. Sebagai elemen penting dalam teori musik, pengenalan Chord secara otomatis memperlihatkan tantangan kompleksitas tersendiri. Oleh karena itu, penelitian yang lebih mendalam perlu dilakukan untuk memahami dan membandingkan keunggulan serta keterbatasan masing-masing metode dalam konteks pengenalan Chord pada instrumen musik.

Studi sebelumnya, yang memiliki relevansi terhadap paper dibahas di dalam jurnal ilmiah yang berjudul A Mandarin Tone Recognition Algorithm Based on Random Forest and Feature Fusion [2] telah menunjukkan keberhasilan Ensemble Learning, terutama dengan metode Random Forest, dalam pengenalan pola suara pada konteks pengenalan nada dalam bahasa Mandarin. Meskipun fokusnya bukan pada pengenalan Chord dalam musik, namun penggunaan Random Forest dalam mengenali pola suara menunjukkan potensi yang relevan dengan konteks pengenalan Chord pada instrumen

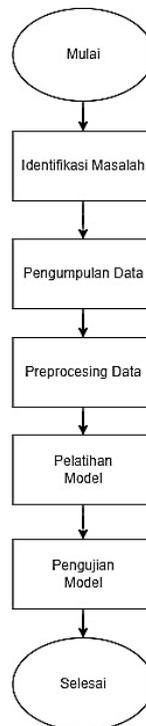
musik. Studi ini berhasil mencapai akurasi pengenalan nada yang tinggi di atas 83.57%, bahkan dengan jumlah sampel latihan yang kecil. Hasil ini memberikan pemahaman bahwa Random Forest memiliki kemampuan pembelajaran yang kuat dalam mengenali pola suara, yang dapat diterapkan dalam pengenalan Chord pada instrumen musik.

Dengan adanya permasalahan tersebut, serta urgensi untuk mengembangkan teknik pengenalan Chord secara otomatis yang lebih efektif, penelitian ini dilakukan. Melalui penelitian ini, diharapkan dapat diperoleh pemahaman yang lebih baik tentang kinerja masing-masing metode dalam konteks pengenalan Chord pada instrumen piano dan gitar. Selain itu, hasil penelitian ini diharapkan dapat memberikan kontribusi baru dalam pengembangan teknik pengenalan Chord secara otomatis, serta memberikan wawasan baru tentang aplikasi Ensemble Learning dalam bidang musik. Dengan demikian, penelitian ini memiliki urgensi yang kuat untuk dilakukan, karena akan memberikan pemahaman yang lebih dalam tentang teknik pengenalan Chord secara otomatis dan potensi penggunaan metode Ensemble Learning dalam konteks musik, yang dapat membawa dampak positif dalam pengembangan industri musik dan teknologi informasi.

2. Metodolgi Penelitian

Flowchart Umum

Pada metodologi penelitian akan membahas langkah- langkah yang akan dilakukan dalam menjalankan penelitian ini. Langkah-langkah tersebut meliputi identifikasi permasalahan, pengumpulan data, Preprocessing Data, Perancangan model, serta Analisis Hasil. Visual dari flowchart berada pada gambar 1.



Gambar 1. Flowchart Alur Kerja

2.1 Persiapan Data Set

Pada tahap ini akan dilakukan pengumpulan data. Data yang digunakan dalam penelitian ini adalah Dataset open source yang berasal dari websie kaggle yang berisikan dua buah kategori folder yang bernamakan label Major dan Minor dan pada setiap folder memiliki banyak Sample Audio yang bertipekan file wav yang berisikan chord yang berasal dari instrument alat musik baik gitar maupun piano. Berdasarkan Tabel 1. Pada label Major memiliki jumlah sampel dengan total yaitu 502, Sementara pada label Minor memiliki jumlah sampel yakni 357 Data audio berformat wav, Sehingga

total dataset mencakupi semua label berjumlah 859. Dengan adanya perbedaan dalam perbandingan jumlah sampel dari antar label akan ditangani pada tahap selanjutnya.

Tabel 1. Informasi Data

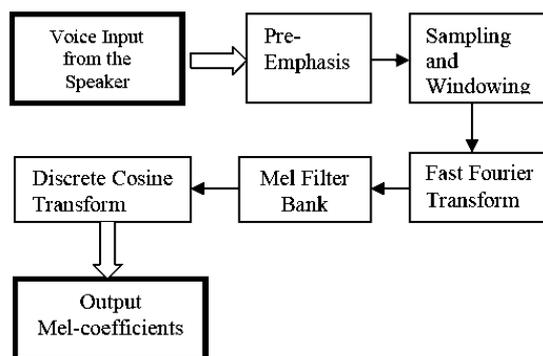
Parameter	Deskripsi	Tipe Data
Audio File	502 (Major) 357 (Minor) Total 859 Files	File (.wav)
Label	Label Chord (Mayor/Minor)	Kategori Folder
Distribusi Panjang Sinyal Audio (Major)	Rata-rata: 49360 Minimum: 48510 Maksimum: 50715	Hz
Distribusi Panjang Sinyal Audio (Minor)	Rata-rata: 49381 Minimum: 47408 Maksimum: 50715	

2.2 Preprocessing data

Pada tahapan ini, dilakukan proses preprocessing data untuk mempersiapkan dataset audio sebelum digunakan dalam model machine learning. Proses preprocessing ini meliputi beberapa langkah seperti di bawah ini :

2.2.1 Ekstrasi Fitur MFCC

Pertama, dilakukan ekstraksi fitur menggunakan metode Mel-frequency cepstral coefficients (MFCC) dari setiap file audio dalam dataset. MFCC adalah representasi fitur yang penting dalam pemrosesan suara, dan ekstraksi ini membantu menggambarkan karakteristik frekuensi dari sinyal audio [5].



Gambar 2. Diagram Alur MFCC [6].

Alur kerja berdasarkan pada gambar 2 dijelaskan flowchart dengan proses pengolahan sinyal suara. Pertama, sinyal suara masuk melalui input suara. Kemudian, dilakukan pre-emphasis untuk meningkatkan sinyal frekuensi tinggi. Selanjutnya, sinyal disampling dan di-windowing untuk membagi sinyal menjadi beberapa segmen yang lebih kecil. Proses fast Fourier transform (FFT) digunakan untuk mengonversi sinyal waktu ke domain frekuensi. Selanjutnya, mel filter bank digunakan untuk memperoleh spektrum energi sinyal dalam rentang frekuensi tertentu. Discrete cosine transform (DCT) digunakan untuk menghasilkan koefisien-koefisien mel yang merepresentasikan karakteristik sinyal suara dalam bentuk domain frekuensi. Output dari proses ini adalah mel-coefficients yang dapat digunakan untuk analisis dan pengolahan lanjutan dalam aplikasi pengenalan suara atau pengolahan sinyal suara lainnya.

2.2.2 Normalisasi (Z-score)

Setelah ekstraksi fitur MFCC, dilakukan normalisasi menggunakan Z-score normalization. Proses normalisasi ini dilakukan untuk memastikan agar distribusi nilai fitur seragam dan memiliki rata-rata nol serta standar deviasi satu.

2.2.3 Oversampling (SMOTE)

Selanjutnya, dilakukan proses oversampling pada label minoritas (kelas Minor) dalam dataset menggunakan metode Synthetic Minority Over-sampling Technique (SMOTE). Oversampling ini bertujuan untuk menyeimbangkan distribusi kelas dalam dataset, sehingga mencegah bias dan meningkatkan kinerja model terhadap kelas minoritas. Setelah melakukan tahap smote, Data akan di bagi menjadi 80:20 untuk data latih dan data uji.

2.3 Random Search

Tuning hiperparameter untuk model hybrid yang ditujukan untuk klasifikasi Model dengan metode Random Search bertujuan sebagai untuk mencari kombinasi hiperparameter yang optimal yang dapat meningkatkan kinerja model dalam tugas klasifikasi.

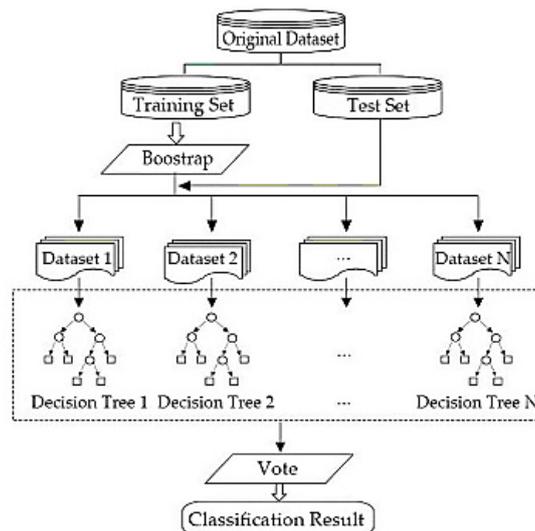
Tabel 2. Kombinasi nilai hyper-parameter yang digunakan

Model	Selected Hyperparameters	Range of Search
Random Forest	n_estimators, max_depth, min_samples_split, min_samples_leaf	[100, 200], [30, 50], [4, 7], [3, 5]
Adaboost	n_estimators, learning_rate	[50, 100, 200] , [0.01, 0.05, 0.1, 0.5, 1]

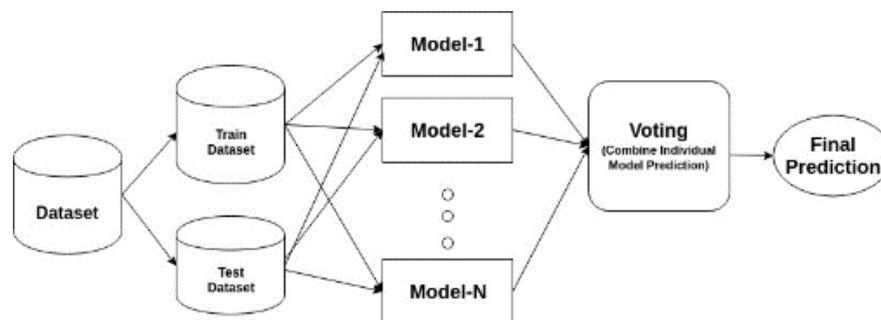
Berdasarkan tabel 2. Penentuan parameter untuk pencarian acak (Random Search) merupakan proses penting dalam pengembangan model machine learning. Dalam Tabel 3.3, parameter yang akan dioptimalkan untuk model Random Forest adalah n_estimators (jumlah pohon dalam ensemble), max_depth (kedalaman maksimum setiap pohon), min_samples_split (jumlah sampel minimum yang diperlukan untuk membagi node), dan min_samples_leaf (jumlah sampel minimum di setiap daun pohon). Rentang pencarian untuk masing-masing parameter didefinisikan sebagai [100, 200] untuk n_estimators, [30, 50] untuk max_depth, [4, 7] untuk min_samples_split, dan [3, 5] untuk min_samples_leaf. Sedangkan untuk model Adaboost, parameter yang akan dioptimalkan adalah n_estimators (jumlah estimators dalam ensemble) dan learning_rate (tingkat pembelajaran). Rentang pencarian untuk n_estimators adalah [50, 100, 200], sedangkan untuk learning_rate adalah [0.01, 0.05, 0.1, 0.5, 1]. Pencarian dilakukan dalam rentang ini untuk menemukan kombinasi parameter yang memberikan kinerja terbaik bagi model yang dibangun. Proses ini membantu dalam menemukan parameter optimal yang menghasilkan model yang memiliki kinerja prediksi yang lebih baik.

2.4 Perancangan Model

Random Forest adalah metode ensemble learning yang menggabungkan output dari beberapa pohon keputusan untuk membuat prediksi akhir. Lalu Adaboost (Adaptive Boosting) adalah algoritma ensemble learning yang digunakan untuk meningkatkan kinerja model dengan menggabungkan beberapa weak learners menjadi satu model yang kuat. Dengan pembangunan kedua model berdasarkan gambar 3 dan gambar 4.



Gambar 3. Arsitektur Model Random Forest



Gambar 4. Arsitektur Model Adaboost

Berdasarkan gambar 3, Arsitektur Random Forest melibatkan gabungan dari beberapa pohon keputusan yang dibangun dengan menggunakan dataset pelatihan yang dibagi menjadi dataset bootstrap. Setiap pohon keputusan dilatih dengan satu dataset bootstrap, dan hasil klasifikasi dari setiap pohon diambil melalui proses voting. Hasil akhir dari klasifikasi ditentukan oleh mayoritas suara dari semua pohon keputusan, yang menjadi output dari Random Forest. Di sisi lain, Pada gambar 4, pembangunan model Adaboost melibatkan inialisasi bobot sampel, iterasi untuk melatih pembelajaran lemah, dan menggabungkan hasil prediksi dari semua pembelajaran lemah menggunakan bobot model mereka untuk mendapatkan prediksi akhir.

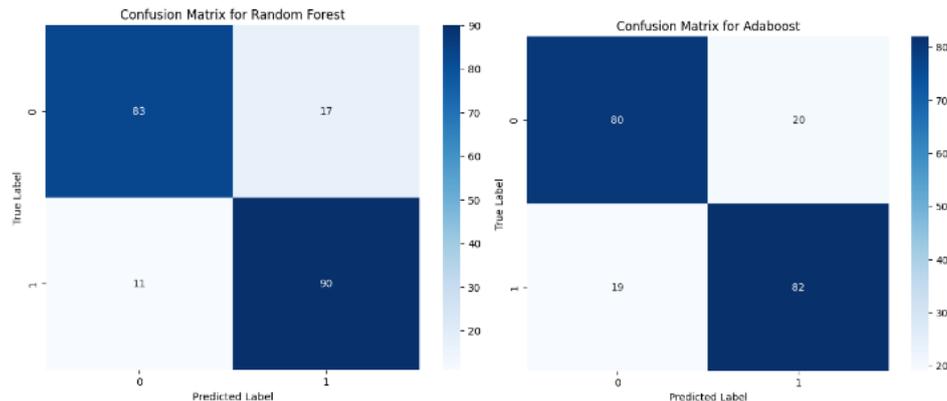
3. Hasil dan Pembahasan

Pada penelitian kali dilakukan perbandingan kinerja antar model ensemble learning Random Forest dengan Adaboost . Hasil eksperimen menunjukkan bahwa Random Forest berhasil mencapai tingkat akurasi sebesar 0.86, sementara Adaboost memperoleh nilai akurasi 0.80. Seperti terlihat pada Tabel 3.

Tabel 3. Hasil evaluasi model dengan menggunakan Random Search

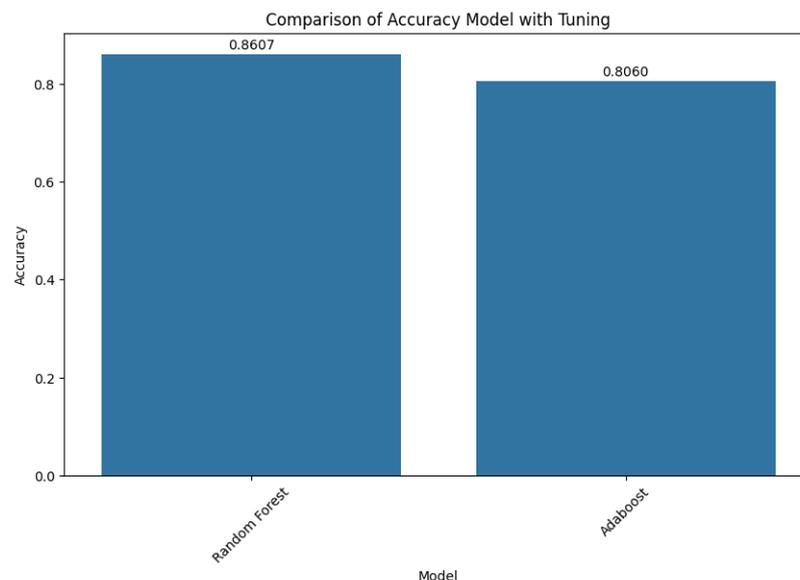
Metrik	Random Forest	Adaboost
Akurasi	0.86	0.80
Presisi	[0.833, 0.848]	[0.808, 0.803]
Recall	[0.85, 0.831]	[0.8, 0.811]
F1-score	[0.841, 0.84]	[0.804, 0.807]
Parameter	n_estimators: 100, min_samples_split: 7, min_samples_leaf: 3, max_depth: 30	n_estimators: 200, learning_rate: 1

Berdasarkan hasil dari tabel 3 menunjukkan bahwa penggunaan teknik RandomizedSearchCV telah berhasil meningkatkan kinerja keduanya model Random Forest dan Adaboost dalam tugas klasifikasi dengan teknik tuning hyperparameter.



Gambar 5. Confusion Matrix Random Forest & Adaboost

Berdasarkan gambar 5. menunjukkan bahwa Confusion Matrix untuk model Random Forest mendapatkan 82% prediksi yang benar untuk kelas positif dan 90% prediksi yang benar untuk kelas negatif, sementara model Adaboost menunjukkan tingkat prediksi yang lebih rendah dengan hanya 80% prediksi yang benar untuk kelas positif dan 82% prediksi yang benar untuk kelas negatif. Dalam konteks penelitian ini, Penulis menginterpretasikan hasil ini sebagai indikasi bahwa model Random Forest lebih mampu dalam mengklasifikasikan data dengan tepat dibandingkan dengan Adaboost. Tingkat prediksi yang lebih tinggi untuk kedua kelas dalam Confusion Matrix Random Forest menunjukkan bahwa model ini memiliki kemampuan yang lebih baik dalam mengidentifikasi kelas-kelas yang berbeda dalam data, memperkuat kesimpulan bahwa Random Forest mungkin merupakan pilihan yang lebih unggul dalam pengklasifikasian data untuk kasus yang diteliti.



Gambar 6. Perbandingan Akurasi Random Forest dengan Adaboost

Dalam konteks penelitian ini, Berdasarkan Gambar 6. Penulis menginterpretasikan hasil ini sebagai indikasi bahwa model Random Forest lebih mampu dalam mengklasifikasikan data dengan lebih baik dibandingkan dengan Adaboost.

4. Kesimpulan

Berdasarkan evaluasi kinerja, Model Random Forest menunjukkan akurasi 81%, lebih tinggi daripada Model Adaboost yang mencapai 74%, menunjukkan perbedaan 7%. Keunggulan Random Forest dalam pengenalan Chord instrumen musik dijelaskan oleh kemampuannya mengenali pola kompleks

dalam data musik, berkat penggabungan banyak pohon keputusan dan adaptasi fitur-fitur informatif. Dalam pengenalan Chord, akurasi klasifikasi sangat penting, sehingga keunggulan Random Forest menjadi faktor penentu pilihan model yang optimal. Penerapan pendekatan Random Search untuk menemukan parameter optimal telah terbukti signifikan dalam meningkatkan kinerja model secara keseluruhan. Dengan menggunakan parameter yang dioptimalkan, akurasi Model Random Forest meningkat menjadi 86%, mewakili kenaikan sebesar 5% dari sebelumnya. Begitu juga, penggunaan teknik pencarian parameter optimal meningkatkan akurasi Model Adaboost menjadi 80%, mencerminkan peningkatan sebesar 6% dari sebelumnya. Ini menegaskan bahwa penyesuaian parameter yang tepat secara substansial meningkatkan kinerja model klasifikasi, menunjukkan dampak positif yang signifikan terhadap akurasi dan kemampuan prediktifnya.

Daftar Pustaka

- [1] Runchuan Li, Wenzhi Zhang, Shengya Shen, Jinliang Yao, Bicao Li, Bing Zhou, Gang Chen, Zongmin Wang. An Intelligent Heartbeat Classification System Based on Attributable Features with AdaBoost & Random Forest Algorithm. *Journal of Healthcare Engineering*. 2021.
- [2] Yan J, Meng Q, Tian L, Wang X, Liu J, Li M, Zeng M, Xu H. A Mandarin Tone Recognition Algorithm Based on Random Forest and Feature Fusion †. *Mathematics*. 2023.
- [3] Ochim Gold, Agaji Iorshase. Heart failure prediction framework using random forest and J48 with Adaboost algorithms . *Science World Journal*. 2023.
- [4] F. Z. SOLAK, "COVID-19 DETECTION USING VARIATIONAL MODE DECOMPOSITION OF COUGH SOUNDS", *KONJES*, vol. 11, no. 2, pp. 354–369, 2023.
- [5] Shen Y, Cheng W. A Tree-Based Machine Learning Method for Pipeline Leakage Detection. *Water*. 2022.
- [6] Ali, Shalbbya, et al. "Mel frequency cepstral coefficient: a review." *ICIDSSD* 2020.

This page is intentionally left blank.