

PENERAPAN ALGORITMA RANDOM FOREST DALAM PREDIKSI EMOSI MUSIK BERDASARKAN KARAKTERISTIK FITUR AUDIO SPOTIFY

Nabila Defany Marsya¹⁾, Muhammad Mufrih Munadhil²⁾, M Alvin Dzakyanta³⁾,
Khusnatul Amaliah^{4)*}, Dani Rofianto⁵⁾

^{1,2,3,4,5}Teknologi Rekayasa Perangkat Lunak, Politeknik Negeri Lampung

Corresponding Author: ¹ nabiladefanymarsya@gmail.com

Article Info

Article history:

Received: June 24, 2025

Revised: July 20, 2025

Accepted: July 30, 2025

Published: Agust 27, 2025

Keywords:

Music Emotion

Random Forest

Machine Learning

Spotify

Fitur Audio

ABSTRACT

Emotion classification in music is a crucial aspect in developing context-aware recommendation systems that respond to the listener's mood. The Random Forest algorithm is used to map song emotions based on Spotify audio features, namely valence, energy, loudness, and danceability, which reflect the psychological and acoustic aspects of music. The dataset was collected through the Spotify Web API and public repositories, consisting of songs released between 2009 and 2019. Data processing involved normalization and labeling emotions into five categories: Angry, Calm, Happy, Neutral, and Sad. The model was trained using 70% of the data and tested with the remaining 30%. Evaluation results showed an accuracy of 98.75%, with perfect F1-scores for the Happy and Sad categories. Valence and energy were found to be the most influential features, while Calm was often confused with Neutral due to similar acoustic patterns. These findings demonstrate that the Random Forest approach is effective in accurately and consistently classifying music emotions based on audio features.



This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY SA 4.0)

1. INTRODUCTION

Musik tidak hanya berfungsi sebagai bentuk hiburan atau ekspresi seni, tetapi juga merupakan media komunikasi emosional yang kompleks dan universal. Penelitian lintas disiplin telah menunjukkan bahwa musik memiliki kemampuan untuk membangkitkan, merepresentasikan, dan memodulasi emosi manusia secara signifikan, baik secara sadar maupun tidak sadar. Oleh karena itu, pengenalan dan klasifikasi emosi dalam musik (Music Emotion Recognition/MER) menjadi salah satu topik penting dalam bidang kecerdasan buatan, ilmu komputer, dan psikologi kognitif. Dalam konteks era digital saat ini, kemampuan sistem untuk memahami dan mengelompokkan musik berdasarkan dimensi emosionalnya sangat diperlukan, terutama dalam pengembangan sistem rekomendasi musik, terapi berbasis musik, dan pengalaman pengguna yang lebih adaptif dan personal.

Platform seperti Spotify menyediakan berbagai fitur audio numerik yang dapat digunakan untuk merepresentasikan karakteristik emosional dari lagu secara objektif, seperti *valence*, *energy*, *loudness*, dan *danceability* [10], [25]. *Fitur valence* menunjukkan

tingkat afektivitas positif atau negatif dari lagu, seperti emosi positif (bahagia) dan negatif (sedih), *energy* merepresentasikan kekuatan atau intensitas musik, sementara *loudness* dan *danceability* berhubungan dengan dinamika serta ritme lagu yang berpotensi memengaruhi respon fisiologis dan emosional pendengar. Pemanfaatan fitur-fitur ini telah membuka peluang besar dalam pengembangan model prediktif berbasis data untuk memahami emosi dalam musik secara otomatis.

Untuk mengatasi tantangan dalam klasifikasi emosi musik, penelitian ini mengusulkan penggunaan algoritma Random Forest, sebuah metode *ensemble learning* berbasis pohon keputusan yang dikenal memiliki performa klasifikasi yang baik dan stabil. Random Forest unggul dalam menangani data berukuran besar dan berdimensi tinggi, serta tahan terhadap masalah *overfitting* yang sering terjadi pada algoritma pembelajaran lainnya. Selain itu, algoritma ini juga mampu melakukan seleksi fitur secara internal, sehingga dapat mengidentifikasi variabel audio yang paling relevan terhadap output emosi [18].

Sejumlah studi sebelumnya telah membuktikan efektivitas algoritma Random Forest dalam domain musik, di antaranya untuk klasifikasi suasana hati

(mood classification) [23], prediksi popularitas lagu berbasis fitur Spotify [17], [21], serta pengklasifikasian genre musik melalui ekstraksi fitur spektral seperti Mel-Frequency Cepstral Coefficients (MFCC) dan Short-Time Fourier Transform (STFT) [5], [24]. Tidak hanya itu, pendekatan multimodal yang menggabungkan fitur akustik, lirik, serta metadata telah terbukti mampu meningkatkan akurasi sistem pengenalan emosi dalam musik secara signifikan [1], [20]. Kajian-kajian tersebut menunjukkan bahwa algoritma Random Forest memiliki potensi tinggi dalam membangun sistem klasifikasi emosi musik yang andal dan efisien.

Melalui dasar pemikiran tersebut, penelitian ini bertujuan untuk menerapkan algoritma Random Forest dalam sistem klasifikasi otomatis emosi musik berdasarkan fitur audio Spotify. Dengan memanfaatkan fitur numerik seperti *valence*, *energy*, *loudness*, dan *danceability*, sistem ini diharapkan dapat mengklasifikasikan lagu ke dalam kategori emosional tertentu secara akurat. Hasil dari penelitian ini diharapkan dapat berkontribusi terhadap pengembangan teknologi pengelolaan musik digital, meningkatkan kualitas sistem rekomendasi berbasis suasana hati pengguna, serta menjadi landasan bagi pengembangan sistem-sistem cerdas lainnya yang bersentuhan dengan persepsi emosional terhadap musik.

2. MATERIALS AND METHODS

Penelitian ini dilakukan melalui beberapa tahapan sistematis untuk membangun model klasifikasi emosi musik berbasis algoritma Random Forest. Setiap tahapan bertujuan untuk memastikan kualitas data, ketepatan proses klasifikasi, dan validitas hasil evaluasi. Tahapan tersebut terdiri atas pengumpulan dan pengelolaan data, pra-pemrosesan data, pemodelan, evaluasi performa model, serta visualisasi hasil klasifikasi.

2.1. Pengumpulan dan Pengelolaan Data

Data yang digunakan berasal dari platform Spotify, yang menyediakan berbagai fitur audio numerik yang relevan untuk analisis emosi dalam musik, seperti *valence*, *energy*, *danceability*, dan *loudness*. Selain itu, atribut teknis lain seperti *acousticness*, *speechiness*, dan *liveness* turut digunakan karena memiliki kontribusi terhadap karakter emosional sebuah lagu.

Proses pengambilan data dilakukan melalui Spotify Web API yang memungkinkan akses langsung ke metadata dan fitur audio lagu secara komprehensif. Selain itu, digunakan juga dataset dalam format CSV yang bersumber dari repositori publik dan dirancang untuk keperluan analisis fitur audio Spotify. Lagu-lagu yang dikumpulkan berasal dari rentang tahun 2009 hingga 2019, dengan tujuan mencakup berbagai

variasi genre dan perkembangan tren musik selama satu dekade terakhir [10], [17].

Langkah awal pengelolaan data melibatkan proses validasi dan pembersihan terhadap entri yang tidak lengkap, duplikat, atau tidak sesuai format. Data kemudian difilter agar hanya menyisakan lagu-lagu dengan fitur audio yang lengkap dan representatif. Tahapan ini penting untuk menjamin kualitas input yang digunakan dalam pelatihan model klasifikasi emosi [23].

Setelah data terkumpul dan bersih, dilakukan pembagian dataset menjadi dua bagian: 70% sebagai data latih untuk proses pembelajaran model dan 30% sebagai data uji untuk evaluasi performa. Pembagian dilakukan secara acak untuk menghindari bias distribusi label emosi dan memastikan generalisasi model terhadap data yang belum dikenali sebelumnya [18], [21]. Pengelolaan data yang cermat sangat menentukan keberhasilan proses klasifikasi karena data yang tidak berkualitas dapat menyebabkan penurunan akurasi secara signifikan.

Table 1. Spesifikasi Atribut Audio

No.	Atribut	Deskripsi
1	Loudness (dB)	Tingkat kekerasan suara
2	Popularity	Tingkat popularitas lagu di Spotify
3	Beats Per Minute (BPM)	Kecepatan irama lagu (tempo)
4	Valence	Tingkat positiveness/emosi lagu
5	Energy	Tingkat energi lagu
6	Danceability	Kemampuan lagu untuk digunakan menari
7	Liveness	Kemungkinan rekaman live
8	Acousticness	Tingkat keakustikan suara
9	Speechiness	Proporsi suara percakapan dalam lagu

Data yang diperoleh kemudian dibagi menjadi dua bagian:

- 1) Data latih (training set) sebesar 70% dari total data
- 2) Data uji (testing set) sebesar 30%

2.2. Pra-Pemrosesan Data

Data yang telah dikumpulkan perlu diproses sebelum digunakan dalam proses pelatihan model. Tahapan pra-pemrosesan yang dilakukan antara lain:

- 1) Pembersihan data dari nilai kosong dan duplikat,

- 2) Konversi tipe data menjadi format numerik yang sesuai,
- 3) Normalisasi data numerik menggunakan *Standard Scaler* dengan rumus:

$$Z \frac{x - \mu}{\sigma}$$

di mana:

- 1) x : nilai fitur.
- 2) μ : rata-rata dari data latih.
- 3) σ : simpangan baku dari data latih.

Jika terdapat label emosi dalam bentuk teks, maka label tersebut dikodekan ke dalam bentuk numerik agar dapat diproses oleh model klasifikasi.

2.3. Pemodelan dan Klasifikasi

Model klasifikasi dibangun menggunakan algoritma *Random Forest Classifier*. Algoritma ini dipilih karena memiliki kemampuan yang baik dalam menangani dataset berdimensi tinggi serta mampu memodelkan hubungan non-linear antar fitur.

Proses pelatihan dilakukan menggunakan data latih (*training data*), sedangkan data uji (*testing data*) digunakan untuk mengevaluasi performa model yang telah dibangun. Evaluasi dilakukan untuk mengukur sejauh mana model mampu melakukan klasifikasi secara akurat terhadap data yang belum pernah dilihat sebelumnya.

2.4. Evaluasi Model

Setelah model dibangun dan dilatih, kinerjanya dievaluasi menggunakan beberapa metrik klasifikasi, yaitu:

- 1) *Accuracy*
- 2) *Precision*
- 3) *Recall*
- 4) *F1-Score*

Evaluasi ini bertujuan untuk mengukur sejauh mana model mampu mengklasifikasikan emosi musik secara tepat berdasarkan fitur-fitur audio.

2.5. Visualisasi Hasil

Hasil evaluasi model dan analisis terhadap fitur-fitur yang berpengaruh dalam proses klasifikasi divisualisasikan menggunakan pustaka Matplotlib dan Seaborn. Visualisasi ini bertujuan untuk memberikan pemahaman yang lebih mendalam terhadap performa model serta kontribusi masing-masing fitur dalam proses klasifikasi. Adapun jenis visualisasi yang digunakan meliputi:

- 1) Barplot untuk menampilkan kontribusi masing-masing fitur (feature importance)
- 2) Confusion matrix untuk menggambarkan performa klasifikasi secara detail

3. RESULTS AND DISCUSSION

Pada Bagian ini menyajikan hasil penerapan algoritma Random Forest dalam memprediksi emosi musik berdasarkan fitur-fitur audio yang diperoleh dari platform Spotify. Dataset yang digunakan berasal dari Kaggle, yang berisi ribuan lagu dengan label emosi seperti *Happy*, *Sad*, *Angry*, *Calm*, dan *Neutral*.

Setiap lagu dilengkapi dengan sejumlah fitur audio, antara lain: *valence*, *energy*, *tempo*, *loudness*, dan *danceability*. Dataset kemudian dibagi menjadi dua bagian, yaitu data latih (*training data*) dan data uji (*testing data*) untuk keperluan pelatihan dan evaluasi model.

Evaluasi terhadap performa model dilakukan menggunakan beberapa metrik, yaitu akurasi, *classification report*, dan *confusion matrix*. Selain itu, dilakukan pula visualisasi *feature importance* untuk mengidentifikasi fitur-fitur yang paling berkontribusi dalam proses klasifikasi emosi.

3.1. Klasifikasi Hasil

Model Random Forest digunakan untuk mengklasifikasikan emosi musik berdasarkan fitur audio dari dataset Spotify, seperti *valence*, *energy*, dan *danceability*. Lima kategori emosi yang digunakan dalam klasifikasi adalah *Angry*, *Calm*, *Happy*, *Neutral*, dan *Sad*, yang dipilih berdasarkan dimensi *valence* dan *arousal* untuk mewakili spektrum emosi dalam musik [1], [2].

Hasil klasifikasi menunjukkan bahwa model mampu mengenali pola emosi secara akurat berdasarkan kombinasi fitur audio. Nilai *valence* terbukti sangat dominan dalam membedakan emosi positif dan negatif, sementara *energy* dan *danceability* membantu membedakan emosi dengan intensitas tinggi seperti *Happy* dan *Angry* dari emosi yang lebih tenang seperti *Calm* dan *Neutral*.

3.1.1. Akurasi Model dan Classification Report

Berdasarkan pengujian terhadap data uji, performa model dikategorikan sangat baik. Tabel berikut menampilkan ringkasan hasil evaluasi klasifikasi.

Table 2. Akurasi Model dan Classification Report

	Precision	Recall	f1-score	Support
Angry	1.00	0.97	0.99	36
Calm	1.00	0.82	0.90	22
Happy	1.00	1.00	1.00	62
Neutral	0.98	1.00	0.99	224
Sad	1.00	1.00	1.00	55
accuracy			0.99	399
macro avg	1.00	0.96	0.97	399
weighted avg	0.99	0.99	0.99	399


Model menunjukkan performa sempurna pada beberapa kategori seperti *Happy* dan *Sad*, dengan nilai

F1-Score sebesar 1.00. Namun, kategori seperti *Calm* memiliki recall yang lebih rendah (0.82), menunjukkan bahwa model masih keliru dalam mengidentifikasi beberapa lagu yang seharusnya masuk ke dalam kategori ini.

Berdasarkan hasil evaluasi, model memperoleh akurasi keseluruhan sebesar 98.75%. Nilai macro average menunjukkan precision 1.00, recall 0.96, dan F1-score 0.97, sedangkan weighted average memberikan hasil precision 0.99, recall 0.99, dan F1-score 0.99. Hasil ini mencerminkan bahwa model mampu mengklasifikasikan emosi musik dengan sangat baik secara umum.

3.1.2. Visualisasi Confusion Matrix

Gambar berikut menampilkan *confusion matrix* dari hasil prediksi model:




Gambar 1. Visualisasi Confusion Matrix

Berdasarkan confusion matrix, dapat dilihat bahwa model mengklasifikasikan label *Neutral* dengan sangat baik (224 benar), diikuti oleh *Happy* (62) dan *Sad* (55). Sebagian besar kesalahan klasifikasi terjadi pada label *Calm*, yang terkadang diprediksi sebagai *Neutral*.

3.1.3. Visualisasi Feature Importance

Analisis terhadap *feature importance* dilakukan untuk mengetahui fitur mana yang paling berpengaruh dalam proses prediksi emosi:



Gambar 2. Visualisasi Feature Importance

Hasil menunjukkan bahwa fitur *valence* dan *energy* adalah yang paling dominan dalam memengaruhi prediksi emosi. Fitur lain seperti *danceability*, *loudness*, dan *acousticness* juga berkontribusi namun tidak sebesar dua fitur utama.

Dari keseluruhan hasil, dapat disimpulkan bahwa model Random Forest sangat efektif dalam mengklasifikasikan emosi musik dengan akurasi tinggi. Performa model konsisten tinggi untuk kategori yang memiliki ciri akustik yang jelas, seperti *Happy*, *Neutral*, dan *Sad*. Namun, *Calm* menjadi kategori yang paling sulit dibedakan, khususnya dari *Neutral*, karena kemiripan dalam pola energi dan valensi.

Temuan ini menunjukkan potensi kuat dari pendekatan machine learning berbasis fitur audio dalam memahami aspek emosional musik. Untuk meningkatkan akurasi di masa mendatang, disarankan eksplorasi fitur tambahan seperti lirik, metadata, atau teknik ekstraksi audio yang lebih kompleks seperti MFCC dan STFT [5], [16], [20].

4. CONCLUSION

Penelitian ini berhasil menerapkan algoritma Random Forest untuk memprediksi emosi musik berdasarkan fitur audio dari dataset Spotify. Model mampu mengklasifikasikan emosi lagu dengan akurasi tinggi sebesar 98.75%, dengan performa terbaik pada kategori *Happy*, *Sad*, dan *Neutral*. Namun, model masih mengalami kesulitan dalam mengidentifikasi kategori *Calm*, yang menunjukkan perlunya pengayaan fitur untuk membedakan emosi yang lebih halus.

Analisis feature importance mengungkapkan bahwa fitur *valence* dan *energy* merupakan faktor utama yang memengaruhi prediksi emosi musik, diikuti oleh *danceability* dan *loudness*. Hasil ini menegaskan relevansi fitur-fitur tersebut dalam representasi emosi pada musik.

Secara keseluruhan, algoritma Random Forest terbukti efektif sebagai metode klasifikasi emosi musik berbasis fitur audio. Penelitian ini memberikan dasar yang kuat untuk pengembangan sistem rekomendasi musik dan aplikasi analisis emosi berbasis audio. Pengembangan lebih lanjut dapat dilakukan dengan menambah fitur lain dan menggunakan metode ekstraksi fitur yang lebih kompleks untuk meningkatkan performa model, terutama pada kategori emosi yang sulit dibedakan.

ACKNOWLEDGEMENTS

Penulis menyampaikan terima kasih kepada dosen pembimbing serta seluruh pihak yang telah memberikan arahan, masukan, dan dukungan selama proses pelaksanaan penelitian hingga penyusunan artikel ini. Setiap kontribusi yang diberikan sangat berarti dalam terselesaikannya karya ilmiah ini.

REFERENCES

- [1] R. Liyanarachchi, A. Joshi, and E. Meijering, "A Survey on Multimodal Music Emotion Recognition," *ACM Comput Surv*, vol. ?, no. ?, 2025, [Online]. Available: <http://arxiv.org/abs/2504.18799>
- [2] J. Kang and D. Herremans, "Towards Unified Music Emotion Recognition across Dimensional and Categorical Models," 2025, [Online]. Available: <http://arxiv.org/abs/2502.03979>
- [3] Z. Hilal, K. Ülkü, and B. Ayhan, "Evaluating raw waveforms with deep learning frameworks for speech emotion recognition," 2025.
- [4] Y. Xia, "Study on Music Emotion Recognition Based on the Machine Learning Model Clustering Algorithm," vol. 2022, 2022, doi: 10.1155/2022/9256586.
- [5] G. Yoo, S. Hong, and H. Kim, "Emotion Recognition and Multi-class Classification in Music with MFCC and Machine Learning," vol. 14, no. 3, pp. 818–825, 2024.
- [6] F. Abri, L. F. Gutiérrez, P. Datta, D. R. W. Sears, A. S. Namin, and K. S. Jones, "A Comparative Analysis of Modeling and Predicting Perceived and Induced Emotions in Sonification," pp. 1–22, 2021.
- [7] L. Cai, S. Ferguson, H. Lu, and G. Fang, "FEATURE SELECTION APPROACHES FOR OPTIMISING MUSIC EMOTION RECOGNITION METHODS," pp. 9–27, 2022, doi: 10.5121/csit.2022.122302.
- [8] N. Falah, B. Yousefimehr, and M. Ghatee, "Predicting Music Track Popularity by Convolutional Neural Networks on Spotify Features and Spectrogram of Audio Waveform," no. February, pp. 1–12, 2025, [Online]. Available: <http://arxiv.org/abs/2505.07280>
- [9] P. L. Louro, H. Redinho, R. Malheiro, R. P. Paiva, and R. Panda, "A Comparison Study of Deep Learning Methodologies for Music Emotion Recognition," *Sensors*, vol. 24, no. 7, pp. 1–17, 2024, doi: 10.3390/s24072201.
- [10] P. Álvarez, J. G. de Quirós, and S. Baldassarri, "RIADA: A Machine-Learning Based Infrastructure for Recognising the Emotions of Spotify Songs," *International Journal of Interactive Multimedia and Artificial Intelligence*, vol. 8, no. 2, pp. 168–181, 2023, doi: 10.9781/ijimai.2022.04.002.
- [11] F. Lv and H. Wang, "Multi-channel enhanced graph convolutional network for sentiment analysis on instrumental music descriptions," *Alexandria Engineering Journal*, vol. 124, no. December 2024, pp. 527–539, 2025, doi: 10.1016/j.aej.2025.03.088.
- [12] X. Hao, H. Li, and Y. Wen, "Real-time music emotion recognition based on multimodal fusion," *Alexandria Engineering Journal*, vol. 116, no. December 2024, pp. 586–600, 2025, doi: 10.1016/j.aej.2024.12.060.
- [13] E. Mardiani *et al.*, "Penerapan Algoritma Supervised Learning untuk Klasifikasi Data Music Listening," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 2, pp. 115–124, 2023, doi: 10.57152/malcom.v3i2.879.
- [14] M. E. İsenkul, "Acta Infologica Optimizing the Sentiment Recognition in Spotify Playlists Through Ensemble-Based Approaches," pp. 1–16, 2025.
- [15] S. S. Gujar and A. Y. Reha, "Enhancing Accuracy and Performance in Music Mood Classification through Fine-Tuned Machine Learning Methods," *Communications on Applied Nonlinear Analysis*, vol. 31, no. 5S, pp. 234–258, 2024, doi: 10.52783/cana.v31i.1019.
- [16] S. Hizlisoy, S. Yildirim, and Z. Tufekci, "Music emotion recognition using convolutional long short term memory deep neural networks," *Engineering Science and Technology, an International Journal*, vol. 24, no. 3, pp. 760–767, 2021, doi: 10.1016/j.jestch.2020.10.009.
- [17] S. Jiang, "Predicting Music Popularity : A Machine Learning Approach Using Spotify Data," no. Mlscm 2024, pp. 324–328, 2025, doi: 10.5220/0013330000004558.
- [18] F. Fakhriza *et al.*, "OPTIMALISASI ALGORITMA RANDOM FOREST FEATURE SELECTION DAN," vol. 9, no. 1, pp. 16–25, 2025.
- [19] S. Mookherjee and S. Dutta, "Exploring the Emotional Landscape of Music: An Analysis of Valence Trends and Genre Variations in Spotify Music Data," pp. 141–146, 2024, doi: 10.20533/icitst.2023.0013.
- [20] T. Krols, Y. Nikolova, and N. Oldenburg, "Multi-Modality in Music: Predicting Emotion in Music from High-Level Audio Features and Lyrics," 2023, [Online]. Available: <http://arxiv.org/abs/2302.13321>
- [21] F. Khan *et al.*, "Effect of Feature Selection on the Accuracy of Music Popularity Classification Using Machine Learning Algorithms," *Electronics (Switzerland)*, vol. 11, no. 21, 2022, doi: 10.3390/electronics11213518.
- [22] Y. Gonzalez and R. C. Prati, "Comparative Study of Musical Timbral Variations: Crescendo and Vibrato Using FFT-Acoustic Descriptor," *Eng*, vol. 4, no. 3, pp. 2468–2482, 2023, doi: 10.3390/eng4030140.
- [23] B. B. Ginn and N. Johnson, "Evaluating the Efficacy of Random Forest in Mood Classification for Music Recommendation System," no. December, 2024, doi: 10.13140/RG.2.2.22524.04485.
- [24] P. Visutsak, J. Loungna, S. Sopromrat, C. Jantip, P. Soponkittikunchai, and X. Liu, "Mood-Based Music Discovery: A System for Generating Personalized Thai Music Playlists Using Emotion Analysis," *Applied System Innovation*, vol. 8, no. 2, 2025, doi: 10.3390/asi8020037.
- [25] P. Saini and P. Shaktawat, "INTELLIGENT SYSTEMS AND APPLICATIONS IN ENGINEERING Identifying Affective Features of Music Tracks to Determine their Popularity using Machine Learning Approach," vol. 12, no. 4, pp. 117–129, 2024.
- [26] M. R. Dalida, L. Bianca Aquino, W. C. Hod, R. Ann Agapor, S. L. Huyo-A, and G. Avelino Sampedro, "Music Mood Prediction Based on Spotify's Audio Features Using Logistic Regression," 2022 *IEEE 14th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and*

Control, Environment, and Management, HNICEM
2022, no. June 2023, 2022, doi:
10.1109/HNICEM57413.2022.10109396.