

Analisis Musik Terhadap Kesehatan Mental Menggunakan Teknik *Classification*

Johanes Fernandes Andry¹, Wandy Wandy², Francka Sakti Lee³, Honni⁴

^{1,3,4}Program Studi Sistem Informasi, Universitas Bunda Mulia,

Jl.Lodan Raya No.2 Jakarta

²Program Studi Sistem Informasi, Universitas Sampoerna, L'Avenue Building,

Jl. Raya Pasar Minggu No.Kav. 16 7, Jakarta

Email : jandry@bundamulia.ac.id

ABSTRAK

Musik memiliki kekuatan dan mendapat tempat di tengah pemikiran masyarakat dalam banyak hal. Ini memiliki efek kehidupan pada setiap makhluk, mulai dari manusia hingga tumbuhan, bunga, burung, hewan dan lain-lain. Musik memiliki peran yang sangat penting dalam mendukung kesehatan mental karena dapat memengaruhi suasana hati, emosi, dan kondisi psikologis seseorang. alasan mengapa musik relevan dalam konteks kesehatan mental yaitu sebagai media ekspresi emosi, mengurangi stres dan Kecemasan. Dalam konteks analisis musik terhadap kesehatan mental, teknik classification dapat digunakan untuk mengelompokkan jenis musik berdasarkan efek psikologisnya pada individu. Penelitian ini bertujuan untuk memahami hubungan antara musik dan dampaknya terhadap kesehatan mental, serta mengembangkan metode berbasis teknik classification untuk mengidentifikasi jenis musik yang dapat memberikan manfaat psikologis tertentu. Untuk mempelajari kecenderungan genre musik yang sering didengarkan dan efeknya terhadap kesehatan mental seseorang bersumber *big data* dari kaggle.com mengenai Musik dan *Mental Health Survey Results* yang akan di olah menggunakan aplikasi RapidMiner dengan teknik Klasifikasi yang merupakan bagian dari *data mining*. Hasil penelitian dengan metode klasifikasi menunjukkan menunjukkan keandalan dalam merekomendasikan musik yang sesuai dengan kebutuhan emosional pengguna. Implikasinya adalah meningkatkan pemahaman masyarakat tentang peran musik dalam mendukung kesehatan mental, sehingga musik dapat dimanfaatkan sebagai alat non-farmakologis dalam kehidupan sehari-hari.

Kata Kunci : Musik, *Mental Health*, *RapidMiner*, *Data Mining*, *Big Data*

ABSTRACT

Music has power and has a place in the midst of people's thoughts in many ways. It has a life effect on every creature, from humans to plants, flowers, birds, animals and others. Music has a very important role in supporting mental health because it can affect a person's mood, emotions and psychological condition. the reason why music is relevant in the context of mental health is as a medium for expressing emotions, reducing stress and anxiety. In the context of music analysis on mental health, classification techniques can be used to group types of music based on their psychological effects on individuals. This study aims to understand the relationship between music and its impact on mental health, and to develop a method based on classification techniques to identify types of music that can provide certain psychological benefits. To study the tendency of music genres that are often listened to and their effects on a person's mental health, big data from kaggle.com regarding Music and Mental Health Survey Results is

sourced from the RapidMiner application with Classification techniques which are part of data mining. The results of the study using the classification method show reliability in recommending music that suits the emotional needs of users. The implication is to increase public understanding of the role of music in supporting mental health, so that music can be used as a non-pharmacological tool in everyday life.

Keywords : *Music, Mental Health, RapidMiner, Data Mining, Big Data*

1. PENDAHULUAN

Musik memainkan peran penting dalam mendukung manusia di semua tahap kehidupan. Dari membantu bayi yang baru lahir mengembangkan ikatan yang sehat dengan orang tuanya hingga menawarkan perawatan paliatif yang vital dan penuh kasih sayang antara orang tua dan anak (Rebecchini, 2022). Musik juga memiliki peranan signifikan dalam kesehatan mental, yang merupakan landasan penting untuk mendorong perkembangan positif pada manusia (Wang et al., 2023). Pengaruhnya melampaui batas wilayah atau negara, menciptakan dampak signifikan pada lingkungan individu di berbagai konteks (Chen, 2023). Hal ini fundamental bagi kesejahteraan keseluruhan individu dan menjadi elemen penting untuk kehidupan yang produktif dan efisien (Hou, 2022).

Krisis kesehatan mental, ditandai dengan meningkatnya prevalensi gejala seperti depresi, kecemasan, gangguan makan, dan penyakit mental lainnya, memerlukan perhatian khusus. Situasi ini mendorong dilakukannya berbagai studi untuk mencari solusi yang relevan (Wang et al., 2022). Penelitian terdahulu cenderung mengeksplorasi area-area stabil dalam psikologi perkembangan, seperti perbedaan usia dan gender dalam merespons pemicu stres yang signifikan (Schwartz, 2021). Dalam konteks ini, musik menjadi salah satu intervensi non-farmakologis yang penting, dengan efek penyembuhan yang signifikan terhadap depresi dan kondisi mental lainnya (Sanfilippo et al., 2021).

Intervensi menggunakan musik, seperti terapi musik, telah terbukti sebagai metode yang efektif dalam pengaturan dan pengendalian kesehatan mental (Vidas et al., 2021). Terapi musik melibatkan intervensi musik yang disesuaikan secara personal dan diinisiasi oleh terapis musik yang terlatih dan berkualifikasi. Hal ini membedakan terapi musik dari intervensi musik lain, seperti musik medis, yang biasanya hanya melibatkan pendengaran musik yang ditawarkan oleh profesional kesehatan (De-Witte et al., 2022). Terapi musik bertujuan untuk meningkatkan efikasi klinis dan manfaat paliatif melalui

partisipasi aktif bersama terapis musik (Liang et al., 2021). Oleh karena itu, penting untuk memahami bagaimana musik dapat memengaruhi kesehatan mental seseorang secara mendalam.

Penelitian ini bertujuan untuk mempelajari kecenderungan genre musik yang sering didengarkan dan efeknya terhadap kesehatan mental seseorang. Analisis ini dilakukan dengan menggunakan data besar dari Kaggle.com mengenai *Music & Mental Health Survey Results*. Untuk mencapai tujuan tersebut, digunakan teknik data mining berupa *classification*. Teknik ini berguna untuk memprediksi kelas atau kategori tertentu berdasarkan data yang ada, dengan langkah-langkah berupa konstruksi model untuk menggambarkan kelas-kelas yang telah ditentukan, dan prediksi untuk mengklasifikasikan data baru atau yang tidak diketahui (Marandi, 2021).

Secara garis besar, *classification* terbagi menjadi dua jenis: *supervised* (terawasi) dan *unsupervised* (tidak terawasi). *Supervised learning* menggunakan umpan balik langsung untuk prediksi dan melibatkan algoritma seperti KNN, *Decision Tree* (DT), *Support Vector Machine* (SVM), *Logistic Regression* (LR), *Artificial Neural Network* (ANN), dan *Naïve Bayes* (NB). Sementara itu, *unsupervised learning* digunakan untuk menemukan pola tersembunyi dalam data, dengan pendekatan seperti analisis komponen utama (PCA) dan analisis kluster (Chauhan et al., 2021). Detail teknis mengenai metode ini akan dijelaskan lebih lanjut dalam bagian metodologi.

Dengan memanfaatkan teknik *classification*, penelitian ini diharapkan dapat mengungkap pola hubungan antara genre musik yang sering didengarkan dan kesehatan mental seseorang. Temuan ini diharapkan memberikan kontribusi signifikan dalam pengembangan terapi musik dan aplikasi berbasis teknologi yang mendukung kesehatan mental individu secara lebih personal.

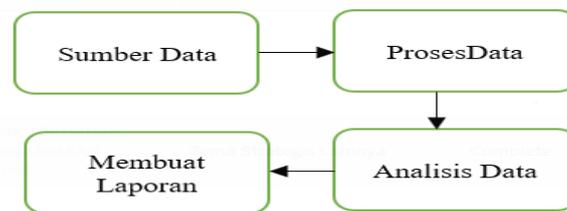
2. METODE

Berdasarkan Gambar 1. Tahapan Penelitian, Penelitian ini dilakukan secara teratur dan sistematis meliputi empat tahapan utama: sumber data, pemrosesan data, analisis data, dan pelaporan hasil. Berikut adalah penjelasan masing-masing tahapan:

- Sumber Data, Peneliti mendapatkan data dari platform Kaggle, yang digunakan untuk analisis lebih lanjut (Andry et al., 2023). Data tersebut diperoleh melalui

tautan berikut: <https://www.kaggle.com/datasets/catherinerasgaitis/mxmh-survey-results>.

- Proses Data, Pada tahap ini, peneliti memproses dataset dengan melakukan filterisasi nilai-nilai kosong serta perubahan format data agar siap untuk analisis berikutnya (Geasela, 2024). Teknik filterisasi dilakukan menggunakan alat seperti Python (library pandas dan numpy) atau RapidMiner. Peneliti menghapus data dengan nilai kosong yang signifikan atau melakukan imputasi pada data yang kurang, tergantung pada tingkat keparahan kehilangan data.
- Analisis Data, Peneliti menganalisis dataset menggunakan RapidMiner dengan metode klasifikasi (Madyatmadja et al., 2021). Algoritma klasifikasi seperti decision tree dan Naive Bayes digunakan untuk memprediksi pengaruh genre musik terhadap kesehatan mental. Evaluasi hasil dilakukan menggunakan metrik seperti akurasi, precision, dan recall untuk mengukur performa model.
- Pelaporan Hasil, Peneliti menyusun laporan dari hasil analisis data yang diperoleh, mencakup interpretasi hasil dan implikasi dari temuan penelitian.



Gambar 1: Flow Penelitian (Madyatmadja et al., 2021)

Dari link tabel tersebut, spesifikasi atribut/kolom *dataset* berdasarkan Tabel 1 Sumber data adalah:

- Timestamp*: Waktu responden mengumpulkan kuesioner.
- Age*: Usia responden.
- Primary streaming service*: Layanan streaming musik yang sering digunakan oleh responden.
- Hours per day*: Jumlah jam responden mendengarkan musik per hari.
- While Working*: Responden mendengarkan atau tidak mendengarkan musik saat belajar/bekerja.
- Instrumentalist*: Responden secara rutin memainkan atau tidak memainkan instrumen.

- g. *Composer*: Responden mengarang atau tidak mengarang musik.
- h. *Fav Genre*: Musik kesukaan responden.
- i. *Exploratory*: Responden secara aktif mengeksplorasi atau tidak mengeksplorasi artis/genre baru.
- j. *Foreign Languages*: Musik yang didengarkan oleh responden menggunakan bahasa asing dari bahasa asal responden.

Tabel 1. Sumber Data

<i>Timestamp</i>	<i>Age</i>	<i>Primary streaming service</i>	<i>Hours per day</i>	<i>While working</i>	<i>Instrumentalist</i>	<i>Composer</i>	<i>Fav genre</i>	<i>Exploratory</i>	<i>Foreign languages</i>
8/27/2022 23:39	16	Spotify	8	Yes	No	No	Hip hop	Yes	Yes
8/27/2022 23:39	16	Spotify	12	Yes	No	Yes	Hip hop	Yes	Yes
8/27/2022 21:28	18	Spotify	4	No	No	No	Video game music	No	Yes
8/27/2022 21:40	61	YouTube Music	2,5	Yes	No	Yes	Jazz	Yes	Yes
8/27/2022 21:54	18	Spotify	4	Yes	No	No	R&B	Yes	No
8/27/2022 21:56	18	Spotify	5	Yes	Yes	Yes	Jazz	Yes	Yes
8/27/2022 22:00	18	YouTube Music	3	Yes	Yes	No	Video game music	Yes	Yes
8/27/2022 22:18	21	Spotify	1	Yes	No	No	K pop	Yes	Yes
8/27/2022 22:33	19	Spotify	6	Yes	No	No	Rock	No	No
8/27/2022 22:44	18	I do not use a streaming service.	1	Yes	No	No	R&B	Yes	Yes

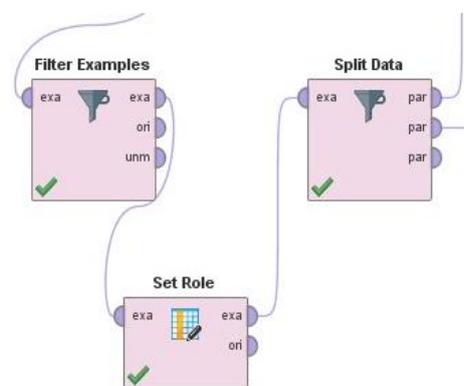
3. HASIL DAN PEMBAHASAN

Pada bagian ini menjelaskan proses dan langkah-langkah yang dapat digunakan untuk mengimplementasikan klasifikasi Rapidminer *Classification* dengan menggunakan *algoritma retrieve*, setiap proses akan dicantumkan dalam bentuk gambar. Untuk memulai proses klasifikasi yaitu

- a. Proses: Ini adalah titik awal, menunjukkan inisiasi suatu proses.
- b. Mengambil: Langkah ini melibatkan pengambilan data atau informasi dari suatu sumber. Ikon dengan anak panah melengkung menunjukkan tindakan pengambi-

lan. Koneksi "inp" (input) menunjukkan dari mana data diambil, dan koneksi "out" (output) menunjukkan kemana data dikirim.

- c. **Filter Contoh:** Langkah ini melibatkan penyaringan data yang diambil menggunakan kriteria atau aturan tertentu. Ikon dengan corong menunjukkan proses penyaringan. Koneksi "exa" (contoh) menunjukkan contoh input, dan koneksi "ori" (asli) dan "unm" (tidak cocok) menunjukkan output yang disaring. Koneksi "exa" diulang karena proses penyaringan kemungkinan menggunakan beberapa contoh. Selanjutnya proses bisa di lihat pada Gambar 2 yaitu Proses *Set Role dan Split Data*.



Gambar 2: Proses *Set Role dan Split Data*

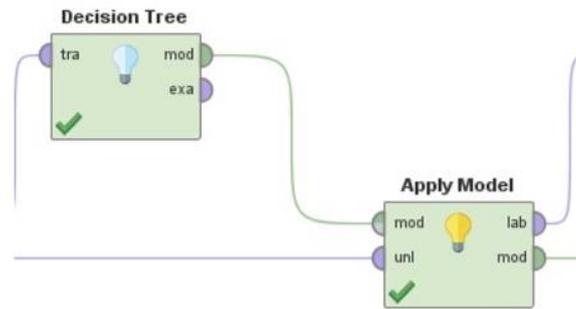
Gambar 2 memperlihatkan langkah-langkah yang umum dilakukan dalam proses *Machine Learning*, khususnya dalam tahap persiapan data.

- Filter Examples:** Langkah ini berfungsi untuk menyaring data yang akan digunakan dalam pelatihan model. Misalnya, kita ingin menghapus data yang memiliki nilai tertentu atau data yang tidak lengkap. Dalam gambar, komponen "*Filter Examples*" menandakan proses penyaringan data.
- Split Data:** Setelah data disaring, langkah selanjutnya adalah membagi data menjadi dua bagian: data pelatihan dan data pengujian. Data pelatihan digunakan untuk melatih model, sementara data pengujian digunakan untuk mengevaluasi performa model. Dalam gambar, komponen "*Split Data*" menandakan proses pembagian data.
- Set Role:** Langkah terakhir dalam persiapan data adalah mendefinisikan peran dari setiap kolom dalam data. Misalnya, kita perlu mendefinisikan kolom mana yang

merupakan label (target yang ingin diprediksi) dan kolom mana yang merupakan fitur (informasi yang digunakan untuk memprediksi label). Dalam gambar, komponen "*Set Role*" menandakan proses pendefinisian peran kolom data.

Menghubungkan *Split Data* dan *Decision Tree*, menunjukkan aliran data dalam suatu proses. Diagram ini terdiri dari dua kotak atau *node*, yaitu "*Split Data*" dan "*Decision Tree*". *Node* "*Split Data*" memiliki tiga keluaran, yaitu "exa", "par1", dan "par2". Keluaran "exa" akan diteruskan ke *node* "*Decision Tree*", sedangkan keluaran "par1" dan "par2" akan diteruskan ke *node* lain yang tidak ditunjukkan dalam gambar. *Node* "*Decision Tree*" memiliki tiga masukan, yaitu "*training data*", "model parameters", dan "*data example*". "Training data" akan digunakan untuk membangun model, "model parameters" akan digunakan untuk mengatur aturan dalam model, dan "*data example*" akan digunakan untuk melakukan prediksi. Dalam gambar, dapat dilihat bahwa *node* "*Decision Tree*" dan "*Split Data*" telah berhasil dijalankan, yang ditunjukkan oleh ikon centang hijau. Hal ini menunjukkan bahwa proses pemecahan data dan pembuatan model telah berhasil dilakukan.

Gambar 3 menunjukkan diagram alur yang menampilkan dua langkah dalam sebuah proses pembelajaran mesin. *Decision tree*, yang menggunakan data pelatihan untuk membangun sebuah model. *Node* "tra" (pelatihan) menunjukkan bahwa data pelatihan dimasukkan ke dalam model, dan *node* "mod" (model) menunjukkan bahwa model telah dibuat. *Node* "exa" (eksekusi) menunjukkan bahwa model telah dijalankan. Apply model, yang menggunakan model yang telah dilatih untuk memprediksi hasil pada data baru. *Node* "mod" (model) menunjukkan bahwa model yang telah dilatih dimasukkan, dan *node* "lab" (label) menunjukkan prediksi yang dibuat oleh model. *Node* "unl" (tidak dikenal) menunjukkan bahwa data baru yang belum pernah dilihat oleh model dimasukkan. Tanda centang pada setiap langkah menunjukkan bahwa langkah tersebut telah berhasil diselesaikan.



Gambar 3: Menghubungkan *Decision Tree* dan *Apply Model*

Selanjutnya menghubungkan *Apply Model* dan *Performance*, yang merupakan representasi grafis dari serangkaian langkah yang dijalankan oleh proses. Dalam diagram alur ini, ada dua kotak, yang menunjukkan langkah-langkah dalam proses, yang dihubungkan oleh garis yang menunjukkan aliran data di antara langkah-langkah tersebut.

Kotak pertama diberi label "*Apply Model*" dan menunjukkan langkah pertama dalam proses. Di dalam kotak, terdapat beberapa label yang menunjukkan jenis data yang terlibat dalam langkah ini, serta ikon lampu yang menyala, yang mungkin menunjukkan bahwa langkah ini telah berhasil diselesaikan. Kotak kedua diberi label "*Performance*" dan menunjukkan langkah kedua dalam proses. Di dalam kotak, terdapat beberapa label yang menunjukkan jenis data yang terlibat dalam langkah ini, serta ikon tanda persentase, yang mungkin menunjukkan bahwa langkah ini menghitung metrik kinerja tertentu.

Garis-garis yang menghubungkan kotak menunjukkan aliran data di antara langkah-langkah tersebut. Garis hijau menunjukkan bahwa data mengalir dari "*Apply Model*" ke "*Performance*," sementara garis ungu menunjukkan bahwa data mengalir kembali dari "*Performance*" ke "*Apply Model*." Garis beige menunjukkan bahwa data mengalir dari "*Performance*" ke bagian lain dari proses, yang tidak ditampilkan dalam diagram ini.

Secara keseluruhan, diagram alur ini menunjukkan bahwa proses tersebut melibatkan penerapan model dan kemudian mengevaluasi performanya. Data kemudian digunakan untuk memperbaiki model, dan prosesnya diulang sampai model mencapai kinerja yang dapat diterima. Diagram alur ini juga menyoroti hubungan iteratif antara penerapan model dan evaluasi kinerja, yang merupakan aspek penting dalam banyak proses pembelajaran mesin.

Tabel 2. *Confusion Matrix & Accuracy*

Accuracy 73.58%	= True no Af- fect	True Im- prove	True Wors- en	Class Proeci- sion
<i>Pred. No Affect</i>	0	1	0	0.00%
<i>Pred. Im-</i> <i>proved</i>	57	181	6	74.18%
<i>Pred. Worsen</i>	0	1	0	0.00%
<i>Class Recall</i>	0.00%	98.91%	0.00%	

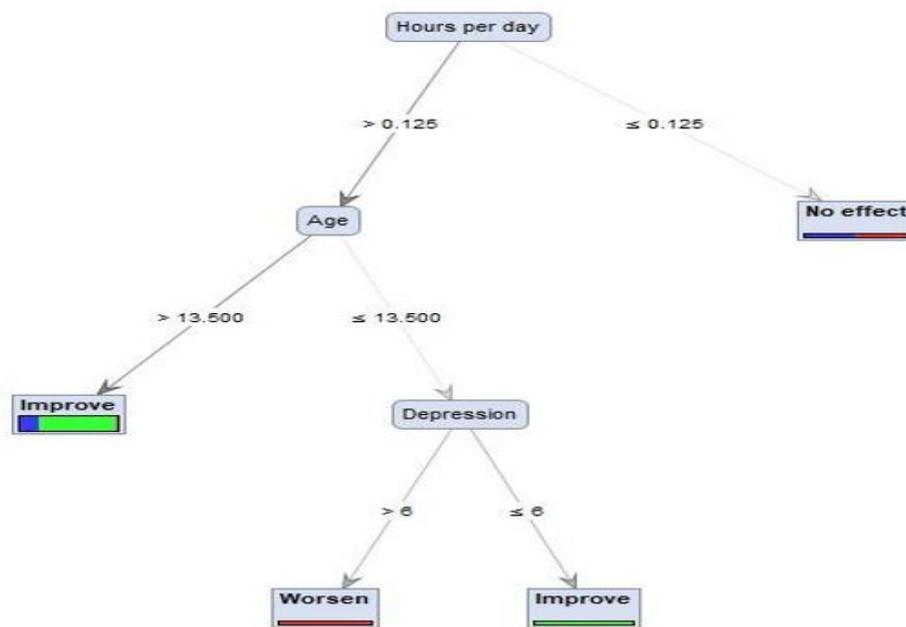
Tabel 3 menunjukkan hasil evaluasi model *machine learning* yang digunakan untuk memprediksi perubahan pada suatu variabel. Model ini diuji dengan data yang memiliki tiga kategori, yaitu No effect, Improve, dan Worsen. Berdasarkan gambar, dapat dilihat bahwa model ini memiliki akurasi sebesar 73,58%. Ini berarti model berhasil memprediksi perubahan yang benar sebesar 73,58% dari seluruh data uji. Namun, jika kita melihat lebih detail pada hasil evaluasi per kategori, terlihat bahwa model memiliki performa yang sangat baik dalam memprediksi kategori Improve dengan recall sebesar 98,91%. Ini berarti model berhasil menemukan hampir semua data yang benar-benar *Improve*. Di sisi lain, model memiliki performa yang sangat buruk dalam memprediksi kategori No effect dan Worsen, dengan recall masing-masing sebesar 0%. Ini berarti model tidak dapat menemukan data yang benar-benar *No effect* dan Worsen sama sekali.

Jika ingin meningkatkan performa model, perlu dilakukan upaya untuk memperbaiki kemampuan model dalam memprediksi kategori No effect dan Worsen. Misalnya, dengan menambahkan lebih banyak data pelatihan untuk kategori tersebut, atau dengan mengubah arsitektur model agar lebih sensitif terhadap perubahan yang kecil.

Gambar 4 merupakan hasil klasifikasi dari model *machine learning*. Model ini mencoba memprediksi apakah seseorang akan mengalami peningkatan, penurunan, atau tidak ada perubahan dalam kondisi mereka berdasarkan beberapa faktor seperti jumlah jam tidur per hari, usia, dan tingkat depresi.

- a. Jika seseorang tidur lebih dari 0.125 jam per hari, maka model akan melihat usia mereka.
- b. Jika usia mereka lebih dari 13.5 tahun, maka model memprediksi kondisi mental mereka akan meningkat.

- c. Jika usia mereka kurang dari 13.5 tahun, maka model akan melihat tingkat depresi mereka.
- d. Jika tingkat depresi mereka lebih dari 6, maka model memprediksi kondisi mental mereka akan memburuk.
- e. Jika tingkat depresi mereka kurang dari 6, maka model memprediksi kondisi mental mereka akan meningkat.
- f. Jika seseorang tidur kurang dari atau sama dengan 0.125 jam per hari, maka model memprediksi bahwa kondisi mental mereka tidak akan berubah.



Gambar 4. Hasil Klasifikasi

Proses klasifikasi dengan metode algoritma *decision tree* yang dilakukan oleh penelitian didasarkan pada tujuan untuk memprediksi perubahan kondisi mental berdasarkan beberapa faktor seperti jumlah jam tidur per hari, usia, dan tingkat depresi. Model ini menunjukkan akurasi sebesar 73.58%, yang berarti model berhasil memprediksi dengan benar 73.58% dari seluruh data uji. Namun, kinerja model sangat bervariasi tergantung pada kategori yang diprediksi. Model memiliki performa yang sangat baik dalam memprediksi kategori "Improve" dengan recall sebesar 98.91%, menunjukkan bahwa hampir semua data yang benar-benar "Improve" berhasil ditemukan. Sebaliknya, model memiliki performa yang sangat buruk dalam memprediksi kategori "No effect" dan "Worsen" dengan recall masing-masing sebesar 0%, yang berarti model tidak dapat

menemukan data yang benar-benar "No effect" dan "Worsen" sama sekali. Hasil ini menunjukkan bahwa meskipun akurasi keseluruhan model cukup tinggi, ada ketidakseimbangan dalam performa model terhadap berbagai kategori yang perlu diperbaiki dengan menambahkan lebih banyak data pelatihan atau mengubah arsitektur model.

Tabel 3. Nilai Kredit Faktor Tahun 2017 (Contoh) ← **12pt, Times New Roman, 1 spasi dan tidak menggunakan garis vertikal**

Faktor	Rasio		
	2014	2015	2016
Manajemen (NPM)	77,75	76,75	77,76
Earning (ROA)	63,01	65,34	64,45
Capital (CAR)	11,35	11,65	11,45

Sumber: Data Sekunder, diolah (2017)

4. SIMPULAN

Berdasarkan pada model klasifikasi yang telah dibangun, didapatkan hasil decision tree sebagai berikut: jika seseorang mendengarkan musik lebih dari 0.125 jam per hari, maka model akan melihat usia mereka. Jika usia mereka lebih dari 13.5 tahun, model memprediksi bahwa kondisi kesehatan mental mereka cenderung meningkat. Jika usia mereka kurang dari atau sama dengan 13.5 tahun, model akan melihat tingkat depresi mereka. Jika tingkat depresi mereka lebih dari 6, model memprediksi bahwa kondisi kesehatan mental mereka dapat menurun. Sebaliknya, jika tingkat depresi mereka kurang dari atau sama dengan 6, model memprediksi bahwa kondisi kesehatan mental mereka cenderung meningkat. Jika seseorang mendengarkan musik kurang dari atau sama dengan 0.125 jam per hari, model memprediksi bahwa kondisi kesehatan mental mereka tidak mengalami perubahan yang signifikan.

Analisis data ini mencakup evaluasi pola-pola dalam mendengarkan musik, termasuk jenis musik yang dipilih, frekuensi, dan durasi mendengarkan musik, serta hubungannya dengan tingkat stres, kecemasan, dan gejala depresi seseorang. Hasil penelitian dengan metode klasifikasi menunjukkan bahwa dua faktor utama yang memengaruhi peningkatan kondisi kesehatan mental seseorang adalah durasi mendengarkan musik (*Hours per day*) dan usia (*Age*).

Model klasifikasi ini dievaluasi menggunakan metrik seperti akurasi, precision, dan recall untuk memastikan kualitas prediksi. Hasil evaluasi menunjukkan bahwa model memiliki performa yang baik dalam mengidentifikasi hubungan antara pola

mendengarkan musik dan kesehatan mental, memberikan wawasan yang relevan untuk intervensi berbasis musik dalam mendukung kesehatan mental individu.

5. DAFTAR PUSTAKA

- Andry, J. F., Sibarani, R., & Yefta, V. N. (2023). Analysis of Big Data Football Club Market Value Using K-Means and Linear Regression Mining Methods. *Journal of Computer Science*, vol. 19, no. 2, pp. 286-294, 2023, [https://doi: 10.3844/jcssp.2023.286.294](https://doi.org/10.3844/jcssp.2023.286.294).
- Chauhan, T., Rawat, S., Malik, S., & Singh, P. (2021). Supervised and unsupervised machine learning based review on diabetes care. In *2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS)*, Vol. 1, pp. 581-585. IEEE. <https://doi.org/10.1109/ICACCS51430.2021.9442021>
- Chen, Q. (2023). Mental Health as a Mediator of the Transformational Leadership to Better Performance. *Journal of Education, Humanities and Social Sciences*. [Online]. Available: <https://doi.org/10.54097/ehss.v8i.4660>
- De-Witte, M., Pinho, A. D. S., Stams, G. J., Moonen, X., Bos, A. E., & van Hooren, S. (2022). Music therapy for stress reduction: a systematic review and meta-analysis. *Health Psychology Review*, 16(1), 134-159. <https://doi.org/10.1080/17437199.2020.1846580>
- Geasela, Y. M., Bernanda, D. Y., Andry, J. F., Jusuf, C. K., Winata, S., Lydia, & Everlin, S. (2024). Analysis of Student Mental Health Dataset Using Mining Techniques," *Journal of Computer Science*, vol. 20, no. 1, pp. 121-128, 2024, [https://doi: 10.3844/jcssp.2024.121.128](https://doi.org/10.3844/jcssp.2024.121.128).
- Hou, J. (2022). Effective Ways for College Students' Mental Health Education Based on Music Therapy. *Journal of Healthcare Engineering*, Hindawi Limited. [Online]. Available: <https://doi.org/10.1155/2022/3031064>
- Liang, J., Tian, X., & Yang, W. (2021). Application of music therapy in general surgical treatment. *BioMed Research International*, 2021. <https://doi.org/10.1155/2021/6169183>
- Matziorinis, A. M., & Koelsch, S. (2022). The promise of music therapy for Alzheimer's disease: A review. *Annals of the New York Academy of Sciences*, 1516(1), 11-17. <https://doi.org/10.1111/nyas.14864>
- Madyatmaja, E. D., Jordan, S. I., & Andry, J. F. (2021). Big Data Analysis Using RapidMiner Studio To Predict Suicide Rate In Several Countries. *ICIC Express Letters Part B: Applications*, 12(8), 757-764. <https://doi.org/10.24507/icicelb.12.08.757>
- Madyatmadja, E. D., Sembiring, D. J. M., Angin, S. M. B. P., Ferdy, D. and Andry, J. F. (2021). Big data in educational institutions using RapidMiner to predict learning effectiveness," *Journal of Computer Science*, vol. 17, no. 4, pp. 403-413. [https://doi: 10.3844/jcssp.2021.403.413](https://doi.org/10.3844/jcssp.2021.403.413)
- Marandi, R. J. (2021). Supervised or unsupervised learning? Investigating the role of

pattern recognition assumptions in the success of binary predictive prescriptions. *Neurocomputing*, 434, 165-193. <https://doi.org/10.1016/j.neucom.2020.12.063>

Rebecchini, L. (2021). Music, mental health, and immunity, *Brain, Behavior, and Immunity -Health*, vol. 18. [Online]. Available: <https://doi.org/10.1016/j.bbih.2021.100374>

Sanfilippo, K. R. M., Stewart, L., & Glover, V. (2021). How music may support perinatal mental health: an overview. *Archives of women's mental health*, 24(5), 831-839. <https://doi.org/10.1007/s00737-021-01178-5>

Schwartz, K. D. (2021). COVID-19 and student well-being: Stress and mental health during return-to-school. *Canadian Journal of School Psychology*, vol. 36, no. 2, pp. 166-185. 2021. [Online]. Available: <https://doi.org/10.1177/08295735211001653>

Vidas, D., Larwood, J. L., Nelson, N. L., & Dingle, G. A. (2021). Music listening as a strategy for managing COVID-19 stress in first-year university students. *Frontiers in psychology*, 12, 647065. <https://doi.org/10.3389/fpsyg.2021.647065>

Wang, K., Gao, S., & Huang, J. (2022). Learning About Your Mental Health From Your Playlist? Investigating the Correlation Between Music Preference and Mental Health of College Students. *Frontiers in Psychology*, vol. 13.[Online]. Available: <https://doi.org/10.3389/fpsyg.2022.824789>

Wang, Q., Zhang, W., & An, S. (2023). A systematic review and meta-analysis of Internet-based self-help interventions for mental health among adolescents and college students,” *Internet Interventions*. [Online]. Available: <https://doi.org/10.1016/j.invent.2023.100690>