

Implementasi Algoritma *Upper Confidence Bound* Untuk Sistem Rekomendasi Musik

Ardan Dwi Hartono^{1*}, Joko Sutopo²

^{1,2}Program Studi Informatika, Fakultas Sains dan Teknologi, Universitas Teknologi Yogyakarta, Indonesia

**email*: ardan.5210411077@student.uty.ac.id

Info Artikel

Dikirim: 22 Oktober 2024
Diterima: 13 November 2024
Diterbitkan: 30 November 2024

Kata kunci:

Sistem Rekomendasi;
Collaborative Filtering;
Reinforcement Learning;
Upper Confidence Bound;
Musik.

ABSTRAK

Sistem rekomendasi menjadi hal yang penting untuk pengguna sebagai informasi kepada hal yang mereka belum ketahui. Selain memudahkan pengguna untuk menemukan informasi, sistem juga dapat meningkatkan kepuasan pengguna dengan memberikan rekomendasi yang akurat dan sesuai dengan preferensi mereka. Dalam penelitian ini sistem rekomendasi dapat berguna bagi pengguna untuk berkeplorasi dan memberikan tanggapannya. Penelitian ini mengembangkan sistem rekomendasi musik berbasis *collaborative filtering* untuk membantu pengguna menemukan lagu-lagu baru yang sesuai dengan preferensi mereka. Metode *Reinforcement Learning* ini adalah metode pembelajaran yang dimana agen berinteraksi dengan lingkungannya. Sistem ini menggunakan dataset Spotify Tracks dan data perilaku pengguna untuk menghasilkan rekomendasi. Algoritma *upper confidence bound* biasanya digunakan pada kasus *multi-armed bandit* dengan menentukan *arm* yang akan dipilih berdasarkan rata-rata dan ketidakpastian dari hasil yang diperoleh. Pada penelitian ini algoritma *upper confidence bound* diterapkan untuk menyeimbangkan eksplorasi lagu-lagu baru dengan eksploitasi lagu-lagu yang sudah diketahui dan disukai pengguna. Hasil penelitian menunjukkan bahwa sistem ini mampu memberikan rekomendasi musik yang relevan dengan karakteristik pengguna.

1. PENDAHULUAN

Terdapat banyak hal yang dapat membuat manusia terhibur salah satunya adalah musik. Selain untuk hiburan, musik juga dibuat untuk mengekspresikan perasaannya lalu dituangkan melalui suara dan irama. Musik sering dikonsumsi secara berurutan, yaitu musik dalam sesi mendengarkan atau *playlist*. Oleh karena itu, sistem rekomendasi musik berfokus pada tugas rekomendasi berurutan seperti pembuatan atau kelanjutan *playlist* otomatis yang memanfaatkan preferensi pengguna jangka panjang dan jangka pendek [1]. Sistem rekomendasi merupakan teknologi yang berguna untuk meringankan masalah kelebihan muatan dari informasi yang disediakan ke pengguna [2]. Sistem rekomendasi musik adalah sistem yang dapat membantu pengguna untuk menemukan musik di database yang sangat besar [3].

Beberapa penelitian sebelumnya telah menggunakan metode yang sama yaitu *collaborative filtering* dalam sistem rekomendasi musik. Seperti penelitian sistem rekomendasi musik *collaborative filtering* yang menggunakan algoritma *SVD++* dan *KNN* [4]. Kemudian terdapat penelitian sistem rekomendasi musik *collaborative filtering* yang menggunakan teknik *MAE* (*Mean Absolute Error*) dan teknik *RMSE* (*Root Mean Squared Error*) [5]. Selanjutnya terdapat penelitian sistem rekomendasi musik *collaborative filtering* yang menggunakan *KNN* dan *PSO* (*Particle Swarm Optimization*) [6]. Penelitian-penelitian tersebut masih memiliki

kelemahan yaitu kemampuan dalam melakukan *data engineering* harus diperhatikan, sehingga performa dan kinerja yang dihasilkan akan jadi lebih baik.

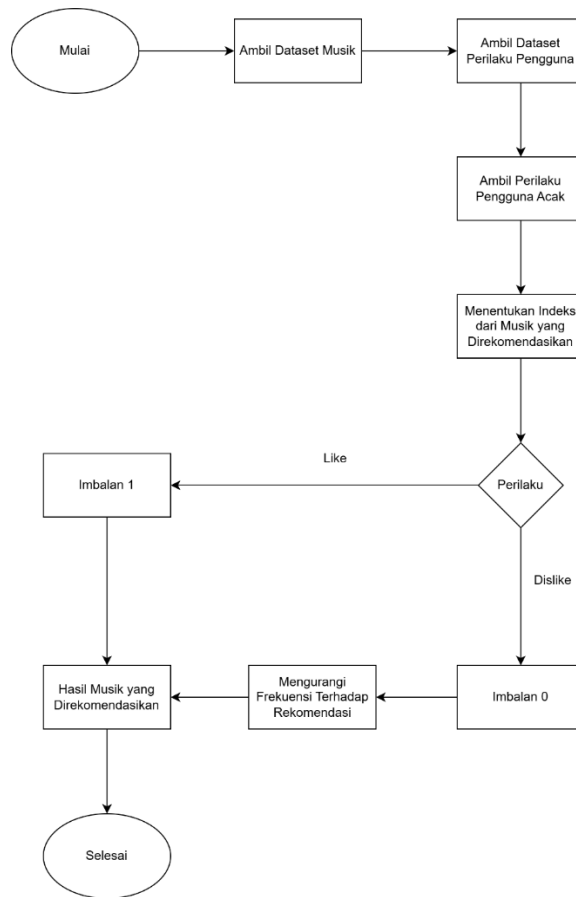
Kemudian ada beberapa penelitian sebelumnya menggunakan metode-metode yang berbeda seperti *Content-Based Filtering* dengan memanfaatkan *cosine similarity* yang kemudian menghasilkan rekomendasi musik dengan hasil nilai *recall* dan hasil nilai *precision* antara 0,150 hingga 0,200 dan antara 0,015 hingga 0,125 [7]. Kedua, terdapat penelitian sistem rekomendasi musik dengan *listening history* musik dan keterkaitan artis Indonesia yang menjadi parameternya kemudian menggunakan metode *case-based reasoning* dengan nilai *precision* keseluruhannya 0,79 [8]. Ketiga, terdapat penelitian tentang sistem rekomendasi lagu dengan metode *content-based filtering* dengan TF-IDF dan *cosine similarity* sebagai tekniknya [9]. Keempat, terdapat penelitian rekomendasi lagu yang menggunakan lirik lagu sebagai parameternya dan menggunakan metode *N-Gram* dan *cosine similarity* sebagai tekniknya yang kemudian memperoleh nilai dari rata-rata *precision unigram* tertinggi yaitu 0,656 dan nilai dari *MAP* tertinggi sebesar 0,82914032 pada *unigram* [10]. Penelitian-penelitian tersebut memiliki beberapa kelemahan seperti diperlukan dokumen lagu yang banyak [10], *dataset* yang lebih banyak dan variatif [9], menggunakan metode *case-based reasoning* berdasarkan data *listening history* sebagai *knowledge base* sehingga memerlukan tempat data yang besar untuk menyimpan *history* tersebut [8], dan buruknya *performance* sistem pada *dataset* yang lebih besar sehingga memerlukan algoritma tambahan sebagai Solusi untuk jumlah data yang banyak [7].

Lalu terdapat beberapa penelitian sebelumnya tentang sistem rekomendasi musik yang menggunakan *reinforcement learning* seperti menggunakan emosi sebagai basisnya [11]. Penelitian tersebut mengajukan sistem rekomendasi musik novel dengan menggunakan emosi sebagai basisnya [11]. Kemudian terdapat penelitian sistem rekomendasi musik menggunakan *non-stationary bayesian reinforcement learning* [12]. Penelitian ini menggunakan metode *content-based* sebagai metode rekomendasi musiknya [12]. Terakhir terdapat penelitian sistem rekomendasi musik berdasarkan aturan novel [13]. Penelitian ini mengembangkan *framework* rekomendasi novel sebagai penalar, pembelajaran dan pengadaptasian untuk preferensi pengguna [13].

Berdasarkan permasalahan yang dihadapi pada penelitian sebelumnya yang telah disebutkan, dengan menggunakan algoritma *Upper Confidence Bound* sistem akan lebih adaptif dan efisien dalam merekomendasikan musik.

2. METODE PENELITIAN

Pada bagian ini data mentah atau asli yang diperoleh dari data musik spotify yang diambil dari Kaggle dengan judul Spotify Tracks Dataset dan Maharshi Pandya sebagai authornya, pada *dataset* tersebut terdapat musik-musik dengan berbagai karakteristiknya seperti judul musik, artis, nama album, id musik, popularitas, dan sejenisnya yang kemudian *dataset* tersebut diubah nama menjadi *dataset_musik*. Kemudian terdapat *dataset* perilaku pengguna yaitu data aktivitas pengguna yang didapatkan dari masukan pengguna dengan cara pengguna melakukan interaksi pada aplikasi yang kemudian hasil dari interaksi tersebut dimasukkan pada *dataset* *data_pengguna*. Alat atau pustaka yang digunakan untuk mengolah *dataset* tersebut yaitu *Pandas*, alat untuk menghitung pengolahan pada algoritma *Upper Confidence Bound* adalah *Numpy*. Desain sistem dari penelitian ini dapat dilihat pada Gambar 1 berikut.



Gambar 1. Desain Sistem

Berdasarkan pada Gambar 1, desain dari sistem memiliki beberapa tahapan pada aplikasi sistem rekomendasi musik. Tahapan utamanya adalah mendapatkan data dari dataset musik dan dataset pengguna, mendapatkan perilaku pengguna acak, menentukan indeks dari rekomendasi musik, menentukan *reward* berdasarkan perilaku pengguna, jika *reward* memiliki indeks 0 maka sistem akan mengurangi frekuensi pemilihan terhadap musik yang direkomendasi, terakhir menghitung probabilitas tertinggi musik untuk direkomendasikan.

2.1 Dataset

Pada penelitian ini digunakan 2 buah metadata, metadata yang digunakan terdiri dari metadata pengguna dan metadata berisi karakteristik musik yang diperlihatkan pada Tabel 1 dan Tabel 2.

Tabel 1. Dataset Pengguna

No.	nama_pengguna	track_id	action
1	Ardan	47RAxX2yfiZWmsNKLvjQON	like
2	Erwan	5BkNCuxzzid0gz9sx3NNbX	dislike
3	Erwan	0cfQ7qEzfu0L4P4wuJPhll	like
4	Ardan	0zwLSC28uUwg55bV9dnAKu	dislike
5	Rizki	1BR2rZ8nZ0pPuRkuyE3oZ2	dislike
6	Satria	6BHDjTwsBQwZKjuFKfBgkK	dislike
7	Satria	4CVpFQ85BvyfZdguokt6zq	like
8	Satria	3zPvL6ZCSVAHvSZXNoAbkl	like
9	Ardan	4ur3Ym08ODiSLHjzrFt7ev	dislike
10	Ardan	50Emj7dvfU5NTCQsS7ECJ7	dislike
...
191	Ardan	2vGDT0tshkco6LVFfdEI2	like

Tabel 1 merupakan ringkasan dari dataset pengguna dari jumlah 191 interaksi pengguna yang terdapat kolom nama pengguna, identitas musik, dan aksi dari pengguna tersebut ke suatu musik.

Tabel 2. Dataset Musik

track_id	(Karakteristik musik seperti artis, judul musik, nama album, popularitas, dan lainnya.)		
0	5SuOikwiRyPMVoIQDJUgSV
1	4qPNDBW1i3p13qLCt0Ki3A
...
113999	2hETkH7cOfq mz3LqZDHZf5		

Tabel 2 merupakan ringkasan dari dataset musik dari jumlah 114.000 musik dengan kolom dari berbagai karakteristik musik seperti nama artis, judul musik, nama album, popularitas, genre, dan lainnya.

Berdasarkan Tabel 1 dan Tabel 2, *dataset* pertama dimasukkan pada variabel *dataframe_lagu*, sedangkan *dataset* kedua dimasukkan pada variabel *datapengguna* dengan memanfaatkan *library* dari *pandas*.

2.2 Sistem Rekomendasi

Sistem rekomendasi adalah alat yang digunakan menyarankan secara otomatis yang relevan kepada peneliti berdasarkan informasi awal yang diberikan oleh pengguna yang lebih mendetail daripada beberapa kata kunci. Dengan mengintegrasikan konteks pengguna dan informasi kontekstual dari konten yang dikonsumsi untuk memberikan rekomendasi yang lebih akurat dan relevan [14].

Sistem rekomendasi adalah alat dan teknik perangkat lunak untuk memberikan saran kepada pengguna tertentu. Saran tersebut merupakan berbagai proses pengambilan keputusan dengan suatu produk [15].

Berdasarkan penjelasan tersebut dapat disimpulkan bahwa sistem rekomendasi adalah suatu alat dan teknik perangkat lunak yang dapat memberikan saran ke pengguna berdasarkan informasi yang awal diberikan oleh pengguna kepada peneliti.

2.3 Reinforcement Learning

Reinforcement learning merujuk pada kelas masalah dalam *machine learning* yang menuntut agen otonom bereksplorasi di lingkungan yang dimana agen mendapatkan informasi tentang kondisi sekarang dan mengambil aksi. Kemudian lingkungannya mengembalikan sinyal *reward* yang dapat positif atau negatif. Agen tersebut memiliki tujuan untuk memaksimalkan kumulatif sinyal *reward* melalui berbagai interaksi [16].

Reinforcement learning ialah pembelajaran apa yang akan dilakukan, bagaimana menggambarkan situasi untuk aksi, dan untuk memaksimalkan sinyal numerikal *reward*. Pembelajar tidak diperintahkan untuk mengambil keputusan, tetapi sebaliknya harus menemukan tindakan mana yang menghasilkan *reward* paling besar dengan mencobanya [17].

Berdasarkan penjelasan tersebut dapat disimpulkan bahwa *Reinforcement Learning* adalah turunan pembelajaran dari *machine learning* yang mengharuskan agen berinteraksi dengan lingkungan untuk mendapatkan informasi yang kemudian akan memutuskan tindakan berdasarkan *reward* yang diperoleh.

2.4 Upper Confidence Bound

Algoritma *upper confidence bound* didasarkan pada prinsip optimisme dalam menghadapi ketidakpastian, yang menyatakan bahwa seseorang harus bertindak seolah-olah lingkungannya semasuk akal mungkin [18]. Algoritma ini juga memiliki banyak bentuk yang berbeda, sesuai dengan asumsi distribusi pada *noise* [18].

Upper Confidence Bound adalah metode yang digunakan dalam konteks masalah *multi-armed-bandit* untuk menentukan *arm* yang akan dipilih berdasarkan rata-rata dan ketidakpastian dari hasil yang diperoleh. *Upper Confidence Bound* juga mengacu pada pendekatan yang menggabungkan informasi tentang rata-rata *reward* yang diharapkan dengan batas atas kepercayaan untuk mengevaluasi potensi *arm* yang dihitung dari distribusi posterior [19].

Langkah algoritma *Upper Confidence Bound* yang digunakan pada penelitian ini yaitu:

- 1) Dalam setiap iterasi n , kita memiliki dua nomor untuk setiap item i :
 - a. $N_i(n)$ – berapa kali *item* i yang terpilih sampai pada iterasi n .
 - b. $R_i(n)$ – Jumlah *reward* dari *item* i sampai pada iterasi n
- 2) Menghitung jumlah rata-rata *reward* dan interval kepercayaan:
 - a. Rata-rata *reward* dari *item* i sampai pada iterasi n

$$\frac{R_i(n)}{N_i(n)} \quad (1)$$
 - b. Interval kepercayaan pada iterasi n dengan

$$\sqrt{\frac{2 \log(n)}{N_i(n)}} \quad (2)$$
- 3) Selanjutnya memilih *item* i yang memiliki maksimal rata-rata *reward* + interval kepercayaan.

Pada langkah 1 menjelaskan perulangan yang terdapat 2 nilai yang akan di olah oleh algoritma *upper confidence bound* yaitu nilai jumlah munculnya musik yang terpilih dan jumlah *reward* dari musik. Langkah 2 menjelaskan cara menghitung rata-rata *reward* dan interval kepercayaan dari algoritma *upper confidence bound*. Langkah 3 menjelaskan tentang seleksi musik yang memiliki nilai maksimal rata-rata *reward* ditambah dengan interval kepercayaan.

2.5 Collaborative Filtering

Collaborative filtering menggunakan interaksi antara item dan pengguna untuk implementasinya, tetapi yang membedakannya dari metode *Collaborative Filtering* berbasis memori adalah bahwa Metode *Collaborative Filtering* adalah teknik dalam sistem rekomendasi yang bergantung pada interaksi antara pengguna dan item yang direkam. Interaksi ini digunakan untuk menghasilkan rekomendasi yang dipersonalisasi.

Collaborative Filtering secara umum dikategorikan menjadi dua jenis utama:

- 1) *Collaborative Filtering* Berbasis Memori: Pendekatan ini memanfaatkan interaksi yang direkam sebelumnya antara pengguna dan item, yang disimpan dalam matriks.
- 2) *Collaborative Filtering* Berbasis Model: Meskipun metode ini juga menggunakan interaksi antara pengguna dan item, metode ini berbeda dari pendekatan berbasis memori dengan menggunakan model laten untuk menjelaskan interaksi ini dengan lebih baik.

Perbedaan ini memungkinkan rekomendasi yang lebih bernuansa berdasarkan perilaku pengguna. Metode ini menggunakan model laten untuk menjelaskan interaksi antara pengguna dan item [20].

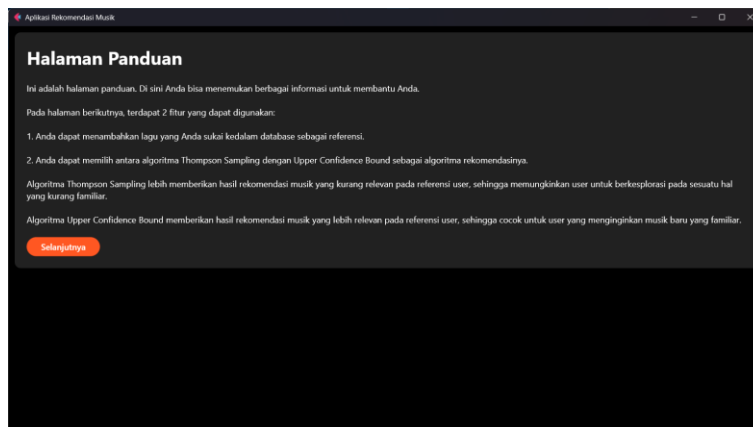
3. HASIL DAN PEMBAHASAN

Penelitian ini telah dilakukan dengan menggunakan data musik sebanyak 114.000 total informasi musik serta 182 total data perilaku pengguna.



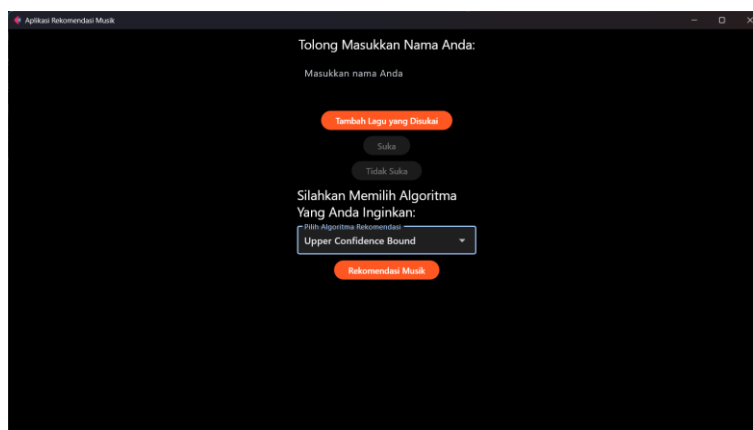
Gambar 2. Tampilan Halaman Selamat Datang

Gambar 2 adalah tampilan dari halaman selamat datang, peneliti menggunakan *library* flet untuk membuat tampilan *user interface*.



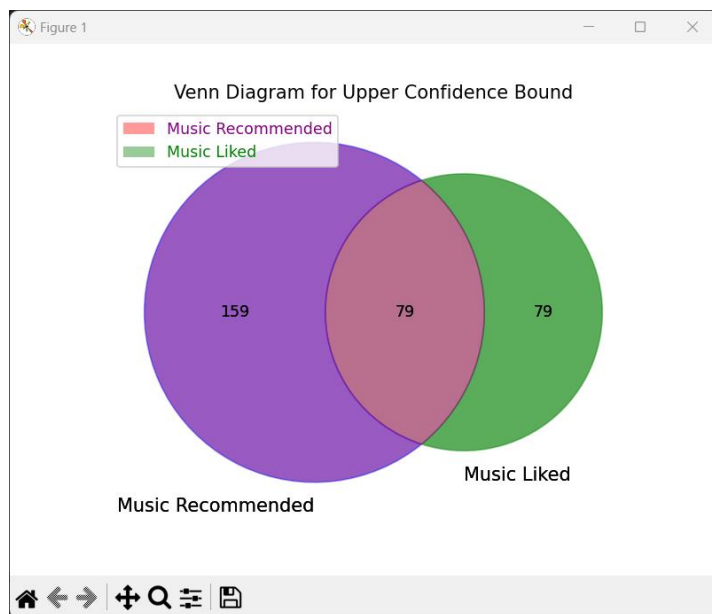
Gambar 3. Tampilan Halaman Panduan

Gambar 3 menunjukkan tampilan dari halaman panduan, pada halaman ini pengguna diberikan intruksi cara penggunaan dari aplikasi ini.



Gambar 4. Tampilan Halaman Utama

Gambar 4 menunjukkan bahwa pengguna dapat memberikan musik kesukaan mereka dengan mengetikkan nama lalu klik tombol “Tambah Lagu yang Disukai” dan kemudian aplikasi akan menampilkan musik acak yang dapat diberikan tanggapan seperti *like* atau *dislike* pada musik tersebut. Kemudian pada Gambar 4 juga terdapat pilihan algoritma yang dapat pengguna pilih sebagai alat rekomendasi.



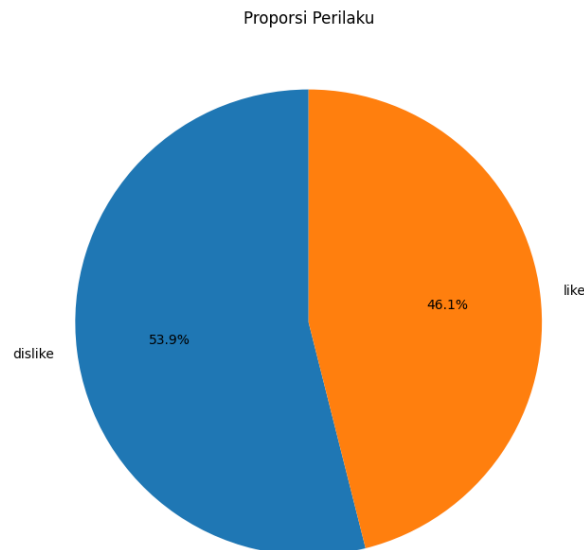
Gambar 5. Tampilan Diagram Venn

Gambar 5 menunjukkan hasil dari musik yang telah direkomendasikan sistem berdasarkan total 159 musik yang diambil dan total 79 musik yang disukai sebagai referensi dari algoritma *Upper Confidence Bound* berdasarkan data pengguna. Kemudian terdapat total 79 hasil musik yang direkomendasikan dengan algoritma *Upper Confidence Bound. Library* yang digunakan untuk menampilkan diagram venn ini ialah *Matplotlib*.

Tabel 3. Kesimpulan dari Hasil Musik yang direkomendasikan oleh Upper Confidence Bound

No.	Music Title	Artist	Genre
1	Ghost – Acoustic	Ben Woodward	Acoustic
2	To Begin Again	Ingrid Michaelson;Zayn	Acoustic
3	Can’t Help Falling In Love	Kina Grannis	Acoustic
4	Hold On	Chord Overstreet	Acoustic
5	Days I Will Remember	Wells	Acoustic
6	Say Something	A Great Big World;Christina Aguilera	Acoustic
7	I’m Yours	Jason Mraz	Acoustic
8	Lucky	Jason Mraz;Colbie Caillat	Acoustic
9	Hunger	Ross Copperman	Acoustic
10	Give Me Your Forever	Zack Tabudlo	Acoustic
11	I Won’t Give Up	Jason Mraz	Acoustic
12	Solo	Dan Berk	Acoustic
13	Bad Liar	Anna Hamilton	Acoustic
14	Hold On – Remix	Chord Overstreet;Deepend	Acoustic
15	Falling in Love at a Coffe Shop	Landon Pigg	Acoustic
...
159	The Flood	Joshua Hyslop	Acoustic

Tabel 3 menunjukkan bahwa banyak daftar rekomendasi musik yang berbeda yang ditampilkan berdasarkan aksi pengguna di dataset perilaku pengguna dan probabilitas tertinggi oleh algoritma *Upper Confidence Bound*. Gambar 6 berikut merupakan perbandingan perilaku pengguna yang ada pada dataset pengguna.



Gambar 6. Proporsi Perilaku Pengguna

Gambar 6 merupakan perbandingan proporsi perilaku pengguna pada dataset pengguna yang dilakukan pada penelitian ini dari jumlah data sebanyak 191.

Berdasarkan pembahasan tersebut yang dilakukan pada jumlah 191 data perilaku pengguna dengan proporsi like 46.1% dan dislike 53.9%, kelebihan dari algoritma *Upper Confidence Bound* ini ialah merekomendasikan musik yang selalu relevan dengan preferensi pengguna pada jumlah 191 data, namun untuk kelemahannya ialah pengguna tidak mendapatkan hasil rekomendasi musik yang berbeda dengan preferensi pengguna.

4. KESIMPULAN

Setelah dilakukan uji coba menggunakan algoritma *upper confidence bound* pada penelitian ini algoritma *Upper Confidence Bound* dapat diimplementasikan dalam sistem rekomendasi dengan melakukan secara *real-time* dan tidak hanya pada rekomendasi musik biasa, tetapi dapat melakukan eksplorasi dan eksploitasi dengan seimbang. Kemudian banyaknya fitur pada dataset musik pada algoritma *Upper Confidence Bound*, tidak terlalu berpengaruh dalam menghasilkan rekomendasi musik yang akurat. Oleh karena itu, *Upper Confidence Bound* sangat cocok digunakan pada rekomendasi musik yang selera penggunanya sama. Pengguna juga dapat lebih mudah untuk menemukan musik-musik baru yang sesuai dengan preferensinya yang bahkan tidak pernah mereka temukan sebelumnya.

Rekomendasi beberapa metode *reinforcement learning* untuk diimplementasikan seperti *Thompson Sampling* sebagai perbandingan hasil rekomendasi atau menggunakan metode *reinforcement learning neural network upper confidence bound* untuk mengetahui performa yang dihasilkan jika ditambahkan model *neural network*. Rekomendasikan untuk menggunakan algoritma *upper confidence bound* ini pada aplikasi lain jika dilihat dari hasil akhir yang diberikan oleh algoritma ini seperti periklanan, robotika, atau optimasi.

REFERENSI

- [1] D. Afchar, A. B. Melchiorre, M. Schedl, R. Hennequin, E. V. Epure, dan M. Moussallam, "Explainability in music recommender systems," *AI Mag*, vol. 43, no. 2, hlm. 190–208, Jun 2022, doi: 10.1002/aaai.12056.
- [2] H. Ko, S. Lee, Y. Park, dan A. Choi, "A Survey of Recommendation Systems: Recommendation Models, Techniques, and Application Fields," *Electronics (Basel)*, vol. 11, no. 1, hlm. 141, Jan 2022, doi: 10.3390/electronics11010141.

- [3] M. Martijn, C. Conati, dan K. Verbert, “‘Knowing me, knowing you’: personalized explanations for a music recommender system,” *User Model User-adapt Interact*, vol. 32, no. 1–2, hlm. 215–252, Apr 2022, doi: 10.1007/s11257-021-09304-9.
- [4] I. Yoshua dan H. Bunyamin, “Pengimplementasian Sistem Rekomendasi Musik Dengan Metode Collaborative Filtering,” *Jurnal Strategi*, vol. 3, no. 1, Mei 2021.
- [5] M. V. Anggoro dan M. Izzatillah, “Sistem Rekomendasi Musik Dengan Metode Collaborative Filtering Berbasis Android,” *STRING(Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 7, no. 1, Agu 2022.
- [6] R. D. M. Rasyid dan Z. K. A. Baizal, “Music Recommender System Using K-Nearest Neighbor and Particle Swarm Optimization,” *Jurnal on Computing*, hlm. 45–54, Agu 2022, doi: 10.34818/indojc.2022.7.2.649.
- [7] A. I. Putra dan R. R. Santika, “Implementasi Machine Learning dalam Penentuan Rekomendasi Musik dengan Metode Content-Based Filtering,” *Edumatic: Jurnal Pendidikan Informatika*, vol. 4, no. 1, hlm. 121–130, Jun 2020, doi: 10.29408/edumatic.v4i1.2162.
- [8] G. S. T. A. V. M. Giri, M. L. Radhitya, M. A. Raharja, dan I. W. Supriana, “Sistem Rekomendasi Musik Berdasarkan Data Konteks Pada Listening History Musik Dan Keterkaitan Artis Indonesia,” *JurnalResistor*, vol. 5, hlm. 1–8, Apr 2022, doi: <https://doi.org/10.31598>.
- [9] N. Ula, C. Setianingsih, dan R. A. Nugrahaeni, “Sistem Rekomendasi Lagu dengan Metode Content-Based Filtering Berbasis Website,” dalam *e-Proceeding of Engineering*, Des 2021, hlm. 12193–12199.
- [10] J. S. Situmorang, P. P. Adikara, dan D. E. Ratnawati, “Rekomendasi Lagu Berdasarkan Lirik Lagu Menggunakan Metode N-Gram dan Cosine Similarity,” vol. 5, no. 6, hlm. 2279–2288, Jun 2021, [Daring]. Tersedia pada: <http://j-ptiik.ub.ac.id>
- [11] R. De Prisco, A. Guarino, D. Malandrino, dan R. Zaccagnino, “Induced Emotion-Based Music Recommendation through Reinforcement Learning,” *Applied Sciences*, vol. 12, no. 21, hlm. 11209, Nov 2022, doi: 10.3390/app122111209.
- [12] B. Bharadwaj, R. Selvanambi, M. Karuppiyah, dan Poonia R, “Content-Based Music Recommendation Using Non-Stationary Bayesian Reinforcement Learning,” *International Journal of Social Ecology and Sustainable Development*, vol. 13, no. 9, hlm. 0–0, Jan 2022, doi: 10.4018/IJSESD.292048.
- [13] D. Hong, Y. Li, dan Q. Dong, “Nonintrusive-Sensing and Reinforcement-Learning Based Adaptive Personalized Music Recommendation,” dalam *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, New York, NY, USA: ACM, Jul 2020, hlm. 1721–1724. doi: 10.1145/3397271.3401225.
- [14] M. Sharma, V. K. Saini, dan J. R. Singh, “Recommendation System,” *International Journal for Modern Trends in Science and Technology*, vol. 6, no. 12, hlm. 484–492, Jan 2021, doi: 10.46501/IJMTST061294.
- [15] F. Ricci, L. Rokach, dan B. Shapira, “Recommender Systems: Techniques, Applications, and Challenges,” dalam *Recommender Systems Handbook*, New York, NY: Springer US, 2022, hlm. 1–35. doi: 10.1007/978-1-0716-2197-4_1.
- [16] D. Ernst dan A. Louette, “Introduction to reinforcement learning,” 2024, hlm. 111–126.
- [17] R. S. . Sutton dan A. G. . Barto, *Reinforcement learning : an introduction*, 2 ed. Cambridge: The MIT Press, 2020.
- [18] T. Lattimore dan C. Szepesvári, *Bandit Algorithms*. Cambridge: Cambridge University Press, 2020.
- [19] D. Russo, “Technical Note—A Note on the Equivalence of Upper Confidence Bounds and Gittins Indices for Patient Agents,” *Oper Res*, vol. 69, no. 1, hlm. 273–278, Jan 2021, doi: 10.1287/opre.2020.1987.
- [20] B. Rocca, “Introduction To Recommender System,” Medium. Diakses: 5 November 2024. [Daring]. Tersedia pada: <https://towardsdatascience.com/introduction-to-recommender-systems-6c66cf15ada>