

PENERAPAN METODE COLLABORATIVE FILTERING DAN AUTOENCODER DALAM REKOMENDASI RESTORAN HALAL

Nauvally Hafizh Revansa^{1*}, Syarif Hidayat²

^{1,2}Informatika, Universitas Islam Indonesia
email: nauvallyhafizh@gmail.com^{1*}

Abstrak: Meningkatnya jumlah restoran tanpa label halal telah menimbulkan kekhawatiran di kalangan masyarakat, khususnya di wilayah dengan mayoritas penduduk non-Muslim. Banyak masyarakat yang merasa tertipu karena kesulitan membedakan restoran halal dan non-halal, terutama karena kurangnya informasi yang jelas. Untuk mengatasi masalah ini, diperlukan sistem rekomendasi yang mampu memberikan informasi mengenai restoran halal dengan tingkat akurasi yang tinggi. Penelitian ini mengusulkan pendekatan *hybrid filtering*, yaitu kombinasi antara *collaborative filtering* dan *autoencoder*, untuk meningkatkan akurasi rekomendasi yang diberikan kepada pengguna. *Collaborative filtering* digunakan untuk menganalisis preferensi pengguna berdasarkan pola pilihan dari pengguna lain yang memiliki kesamaan, sementara *autoencoder* berfungsi untuk menangkap fitur-fitur yang lebih kompleks dalam data restoran. Dataset yang digunakan terdiri dari 19.032 data restoran yang dikumpulkan melalui proses web scraping dari situs *Google Maps*. Selain itu, *cosine similarity* diterapkan untuk mengukur tingkat kesamaan antara preferensi pengguna, sehingga rekomendasi yang dihasilkan lebih relevan dan personal. Tahapan penelitian meliputi pengumpulan dan pemfilteran data, penerapan *cosine similarity*, integrasi *collaborative filtering* dan *autoencoder*, serta evaluasi performa model. Hasil penelitian menunjukkan bahwa metode *hybrid* ini mampu memberikan rekomendasi restoran halal dengan akurasi tinggi, terbukti dari nilai RMSE yang rendah, yang menunjukkan ketepatan sistem dalam memberikan rekomendasi.

Kata Kunci : Rekomendasi, Restoran halal, *Collaborative filtering*, *Autoencoder*

Abstract: The increasing number of restaurants without halal labels has raised concerns in the community, especially in areas with a predominantly non-Muslim population. Many people feel deceived due to the difficulty in distinguishing between halal and non-halal restaurants, mainly due to the lack of clear information. To address this issue, a recommendation system that provides accurate information about halal restaurants is needed. This research proposes a hybrid filtering approach, combining collaborative filtering and autoencoder, to improve the accuracy of recommendations provided to users. Collaborative filtering is used to analyze user preferences based on patterns from other users with similar choices, while the autoencoder captures more complex features in the restaurant data. The dataset consists of 19,032 restaurant entries collected through web scraping from Google Maps. Additionally, cosine similarity is applied to measure the similarity between user preferences, making the recommendations more relevant and personalized. The research stages include data collection and filtering, the application of cosine similarity, integration of collaborative filtering and autoencoder, and performance evaluation of the model. Results show that this hybrid method can deliver highly accurate halal restaurant recommendations, as evidenced by the low RMSE value, indicating the system's precision in providing recommendations.

Keywords : Recommendation, Halal restaurant, Collaborative filtering, Autoencoder

PENDAHULUAN

Digitalisasi menjadi hal yang populer beberapa tahun ini. Mulai dari anak-anak, remaja, hingga dewasa menggunakan *smartphone* sebagai alat bantu dalam kehidupan sehari-hari mereka. Penggunaan *smartphone* ini, telah meningkat dalam beberapa dekade [1]. Hal itu dikarenakan kemudahan yang ditawarkan dan akses yang memadai. Sebagai contoh adalah aplikasi pemesanan hotel dan tempat wisata seperti Traveloka dan Booking.com, atau aplikasi ojek online dan pengantaran makanan, seperti Grab dan Gojek. Aplikasi - aplikasi tersebut menawarkan kemudahan akses dan memberikan banyak opsi bagi para penggunanya.

Sementara itu, industri kuliner berkembang dengan cepat seiring dengan perkembangan teknologi dan informasi, membuat manusia mulai berinovasi untuk membuat berbagai jenis kuliner. Hal tersebut sejalan dengan banyaknya restoran baru yang muncul di beberapa daerah. Berkembangnya industri kuliner dan banyaknya restoran yang tersedia memberikan banyak opsi kepada masyarakat untuk memenuhi salah satu kebutuhan primernya ini. Namun, banyaknya opsi restoran yang tersedia, terkadang membuat masyarakat merasa bingung untuk menentukan pilihannya, terlebih sebagai seorang muslim, sudah sewajarnya memilih restoran yang benar - benar halal.

Sistem rekomendasi dapat menjadi salah satu opsi yang memberikan kemudahan untuk memilih restoran halal sesuai dengan preferensi yang dimiliki oleh masing-masing pengguna. Sistem rekomendasi adalah sebuah teknologi atau algoritma yang digunakan untuk merekomendasikan item, produk, atau konten kepada para pengguna berdasarkan preferensi mereka. Sistem rekomendasi juga dapat membantu pengguna dalam membuat keputusan yang lebih baik dengan mengumpulkan informasi mengenai preferensi mereka dalam berbagai bidang,

seperti produk dan layanan [2]. Dengan adanya sistem rekomendasi, pengguna dapat memilih opsi terbaik dari berbagai pilihan yang ada sesuai dengan apa yang mereka butuhkan.

Salah satu metode yang dapat digunakan untuk merekomendasikan restoran adalah *collaborative filtering*. Metode ini dapat merekomendasikan item atau produk berdasarkan preferensi pengguna. Cara kerjanya adalah dengan membandingkan satu item yang telah disukai atau diberi peringkat oleh pengguna dengan item lainnya yang memiliki kesamaan fitur atau karakteristik. Jika item-item tersebut memiliki kesamaan yang tinggi, maka item yang belum dikonsumsi oleh seorang pengguna dapat direkomendasikan kepada pengguna tersebut [3]. Namun, metode ini akan kesulitan memberikan rekomendasi jika terdapat pengguna baru yang belum mengonsumsi item manapun. Oleh karenanya, menggabungkan metode tersebut dengan *deep learning* akan meningkatkan keberhasilan dalam merekomendasikan restoran.

Deep Learning merupakan cabang dari pembelajaran mesin (*machine learning*) yang berfokus pada penggunaan jaringan syaraf tiruan (*neural networks*) yang sangat kompleks untuk memahami dan memodelkan data [4]. Metode *deep learning* yang digunakan pada rekomendasi restoran ini adalah metode *autoencoder*. *Autoencoder* adalah jenis arsitektur jaringan saraf buatan yang digunakan dalam *deep learning* untuk tugas-tugas seperti reduksi dimensi, *denoising*, rekonstruksi, atau ekstraksi fitur. Dalam pembuatan rekomendasi restoran, *autoencoder* digunakan untuk mengekstraksi fitur-fitur penting dari data restoran seperti menu, lokasi, dan ulasan pelanggan. Oleh karenanya, menggabungkan metode *collaborative filtering* dengan *deep learning*, akan menghasilkan rekomendasi yang lebih akurat [5].

TINJAUAN PUSTAKA


Penelitian tentang sistem rekomendasi wisata kuliner pernah dilakukan oleh [6]. Peneliti melakukan analisis kebutuhan fungsional dan non-fungsional, pengumpulan data, perancangan tampilan, perhitungan manual, pembangunan sistem, dan implementasi metode *Item-Based Collaborative Filtering*. Selain itu, pada penelitian tersebut dilakukan pengujian menggunakan MAE, *Confusion Matrix*, dan *F1 Score*. Hasil pengujian menunjukkan prediksi yang cukup akurat, dengan tingkat akurasi lebih dari 80%. Namun, penggunaan metode *Collaborative filtering* saja belum mampu memberikan rekomendasi ketika ada pengguna baru yang muncul. Oleh karena itu, menggabungkannya dengan metode *deep learning* dapat menjadi solusi efektif untuk mengatasi masalah tersebut, seperti yang akan dibahas dalam penelitian ini.

Sistem rekomendasi memainkan peran penting dalam membantu pengguna membuat keputusan, terutama dalam industri kuliner dengan banyak pilihan. Penelitian sebelumnya telah mengeksplorasi berbagai metode, termasuk *collaborative filtering*, untuk meningkatkan akurasi rekomendasi, terutama dalam konteks makanan dan restoran. Namun, menurut [7], metode ini memiliki keterbatasan, seperti masalah "*cold start*", yaitu ketika pengguna baru tidak memiliki riwayat interaksi. Untuk mengatasi hal ini, beberapa studi telah menggabungkan *collaborative filtering* dengan teknik *deep learning*, seperti *autoencoder*, yang berfungsi mengekstraksi fitur penting dari data guna meningkatkan akurasi rekomendasi. Penelitian [8] menunjukkan bahwa penggunaan *autoencoder* dapat secara signifikan meningkatkan kinerja sistem rekomendasi dalam menangkap pola kompleks dari data pengguna.

Selain itu, penggunaan *cosine similarity* sebagai teknik pengukuran kemiripan juga efektif dalam menghitung tingkat kesamaan antara pengguna berdasarkan ulasan atau penilaian mereka. Studi [9] mengonfirmasi bahwa teknik ini dapat meningkatkan kesesuaian rekomendasi dan memperkuat kepercayaan pengguna. Dengan menggabungkan *cosine similarity*, *collaborative filtering*, dan *autoencoder*, pendekatan *hybrid* ini menawarkan solusi yang lebih holistik dan akurat dalam mengembangkan sistem rekomendasi, khususnya dalam konteks restoran halal yang penting bagi komunitas Muslim di daerah mayoritas non-Muslim.

METODE

Pada bagian ini, metode yang digunakan pada penelitian ini akan dijabarkan. Metode-metode tersebut dapat dilihat pada gambar 1.



Gambar 1. Metode Penelitian

Mengacu pada gambar 1 diatas, metode penelitian terbagi menjadi tujuh bagian, diantaranya persiapan dataset, pemfilteran data, *cosine similarity*, *collaborative filtering*, *autoencoder*, rekomendasi, dan evaluasi. Berikut ini adalah penjelasan dari masing-masing metode:

1. Pengumpulan dataset

Dataset diperoleh dari *platform Google Maps* menggunakan teknik *scraping*. Dataset tersebut terdiri dari 19.032 entri yang mencakup tempat wisata dengan restoran yang menawarkan makanan halal dan non-halal dari beberapa lokasi di provinsi Bali, seperti Denpasar, Gianyar, Ubud, Kuta, Canggu, dan Nusa Dua. Data yang dikumpulkan mencakup informasi pengguna seperti id dan nama pengguna, id restoran, nama restoran, *rating*, *review*, dan penawaran. Pada bagian penawaran, terdapat berbagai layanan yang disediakan oleh restoran, termasuk status apakah restoran tersebut menyediakan makanan halal.

2. Pemfilteran data

Filtering data merupakan proses memilih data spesifik dan menghapus data yang tidak relevan pada dataset untuk digunakan pada pemodelan dan analisis lebih lanjut.

Proses filter dilakukan dengan memilih kalimat “Makanan halal” pada kolom penawaran dalam dataset. Selain itu, ditambahkan juga filter yang menunjukkan restoran tidak mengandung kata-kata seperti Babi, *Pork*, dan *Bacon* pada kolom *review* pengguna. Hal ini memastikan sistem merekomendasikan restoran halal secara lebih akurat.


Tabel 1. Tabel yang telah disaring

Id restoran	Id pengguna	Rating
R00073	US0090	5
R00115	US0011	3
R00065	US0021	4
R00011	US0045	1
R00020	US1020	5

Tabel 1 adalah contoh data yang telah disaring. Ditampilkan tiga kolom utama yang digunakan pada penelitian ini, yaitu id restoran, id pengguna, dan *rating*. Kolom *rating* berisi nilai yang diberikan pengguna pada suatu restoran. Ditampilkan lima buah data dari total 19.032 data dan disimpan dalam dataset *rating*.

3. Autoencoder

Algoritma *autoencoder* dirancang untuk mempelajari representasi data yang informatif, sehingga dapat digunakan dalam sistem rekomendasi [10]. Algoritma ini bertujuan meningkatkan akurasi rekomendasi restoran. *Autoencoder* terdiri dari dua bagian utama, yaitu *encoder* dan *decoder*, dengan struktur ditampilkan pada gambar 2.



Gambar 2. Struktur autoencoder

Berdasarkan gambar 2, data input masuk ke *encoder* untuk menghasilkan representasi yang lebih sederhana. Setelah proses *encoding*, *latent code* mengekstrak fitur penting dari data *input*, lalu *decoder* mengembalikan hasilnya menjadi *output* yang sesuai dengan *input* awal. Penggunaan algoritma *autoencoder* dalam sistem rekomendasi dapat memberikan hasil yang lebih akurat kepada pengguna dibanding sistem yang tidak menggunakan algoritma ini [11].

4. Collaborative filtering

Collaborative filtering merupakan salah satu metode populer dalam sistem rekomendasi. Metode ini menganalisis perilaku pengguna, seperti peringkat, ulasan, dan preferensi. Ide utamanya adalah pengguna dengan preferensi serupa cenderung menyukai item yang mirip. Dengan demikian, sistem dapat memanfaatkan kemiripan ini untuk memberikan rekomendasi yang personal dan relevan [12].

Langkah-langkah dalam *collaborative filtering* adalah sebagai berikut:

- Tentukan pengguna yang akan diberi rekomendasi
 - Hitung nilai kemiripan antar pengguna dengan fungsi *cosine similarity*
 - Berdasarkan hasil *cosine similarity*, tentukan *top N neighbors*
 - Hitunglah nilai prediksi dengan *weighted average*
 - Sajikan rekomendasi restoran berdasarkan nilai tertinggi
- Rumus perhitungan nilai prediksi dengan *weighted average*:

$$weighted\ avg = \frac{\sum (W_{(i,j)} \cdot x_{(u,j)})}{\sum W_{(i,j)}} \quad (1)$$

Keterangan:

weighted avg = rata-rata tertimbang dari rating yang diprediksi

$W_{(i,j)}$ = nilai kemiripan antara pengguna i dan j

$X_{(u,j)}$ = rating pengguna terhadap item j

5. Cosine similarity

Penelitian ini menggunakan *cosine similarity* untuk mengukur kesamaan antara dua vektor, dengan restoran dianggap sebagai sebuah vektor. Metode ini memungkinkan sistem rekomendasi mencocokkan pengguna dengan restoran yang sesuai dengan preferensi mereka secara efektif. *Cosine similarity* dapat dihitung dengan persamaan berikut:

$$\text{sim}(i, j) = \frac{i \cdot j}{|i| \cdot |j|} = \frac{\sum u_{ui} \cdot r_{uj}}{\sqrt{\sum u_{ui}^2} \cdot \sqrt{\sum r_{uj}^2}} \quad (2)$$

Keterangan:

$\text{sim}(i, j)$ = nilai kemiripan vektor i dan j

$i \cdot j$ = hasil perkalian *dot product* antara vektor i dan j

$|i| \cdot |j|$ = akar kuadrat dari jumlah kuadrat setiap elemen dalam vektor

Jika nilai *cosine similarity* antara dua vektor mendekati 1, itu menunjukkan bahwa vektor-vektor tersebut memiliki arah yang identik dan dianggap sangat mirip. Sebaliknya, jika nilai *cosine similarity* mendekati 0, itu menunjukkan bahwa vektor-vektor tersebut memiliki arah yang berbeda dan dianggap kurang mirip [13].

6. Rekomendasi

Pada bagian ini, peneliti akan memberikan rekomendasi restoran halal terbaik dengan skor tertinggi berdasarkan hasil dari sistem rekomendasi.

7. Evaluasi

Evaluasi yang digunakan pada penelitian ini adalah *Root Mean Squared Error* (RMSE). RMSE adalah teknik evaluasi yang banyak dipakai untuk sistem rekomendasi, terutama sistem yang menggunakan *collaborative filtering* [14]. Rumus RMSE adalah sebagai berikut:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum (P_i - r_i)^2} \quad (3)$$

Keterangan:

RMSE = nilai kesalahan rata-rata kuadrat akar (*Root Mean Square Error*)

n = total data yang digunakan

P_i = nilai prediksi untuk item i

r_i = nilai sebenarnya untuk item i

RMSE digunakan untuk mengukur seberapa baik model prediksi dalam mendekati nilai sebenarnya. Semakin kecil nilai RMSE, semakin baik model tersebut dalam melakukan prediksi [15].

HASIL DAN PEMBAHASAN

1. Implementasi proses dan rekomendasi

Langkah pertama dalam proses implementasi adalah pengambilan data dari pengguna yang telah memberikan *rating* ke 10 restoran berbeda. Data tersebut dapat dilihat pada tabel 2. Data yang ditampilkan berupa id restoran, nama restoran, dan *rating*. Sebagai contoh, data diambil dari pengguna dengan id US0071.

Tabel 2. User rating		
Id restoran	Nama restoran	Rating
R00183	Tarunyan Resto Traditional	5
R00090	Raa Cha Suki And BBQ - Level 21 Mall	3
R00102	Pondok Elis Resto	4
R00034	Pandan Kuring Restaurant Living World Denpasar	3
R00056	SUSHI KAWA	5
R00045	BAKUL RESTO Authentic Taste	4
R00021	Wida Resto	4
R00110	Senja Bar & Resto	4
R00033	Rumah Makan Puri Buana Sari	3
R00077	Warung Sakinah (UBK)	3

Menggunakan id restoran yang telah didapatkan, selanjutnya, dilakukan pengelompokan data dengan membuat sebuah tabel pivot yang membandingkan *rating* pengguna target dan pengguna lain ke beberapa restoran. Hal ini bertujuan untuk mempermudah dalam perhitungan kemiripan antar pengguna. Contoh tabel pivot ditunjukkan pada tabel 3.

Tabel 3. Contoh tabel pivot					
Id restoran	R00021	R00033	R00034	R00045	R00056
Id pengguna					
US0071	4	3	3	4	5
US0080	0	3	4	4	5
US1096	2	5	3	1	2
US1112	3	4	5	4	0
US1120	0	3	1	0	4

Setelah tabel pivot berhasil ditampilkan, langkah selanjutnya adalah menghitung nilai kemiripan dengan fungsi *cosine similarity*. Nilai kemiripan ini nantinya akan menentukan rekomendasi yang akan diterima oleh pengguna. Rekomendasi diambil dari pengguna yang memiliki nilai kemiripan tertinggi. *Cosine similarity* dihitung berdasarkan tabel pivot yang telah dibuat sebelumnya.

Tabel 4. Contoh hasil kemiripan pengguna

Nilai kemiripan	Id pengguna
0.758	US0080
0.695	US1096
0.606	US1112
0.700	US1120
0.715	US1124

Tabel 5. Top N neighbors

Nilai kemiripan	Id pengguna
0.976	US0045
0.925	US1022
0.867	US0011
0.802	US1109
0.758	US0080

Tabel 4 menunjukkan nilai kemiripan antar pengguna setelah dihitung menggunakan fungsi *cosine similarity*. Sedangkan tabel 5 adalah lima baris teratas dari keseluruhan data yang memiliki nilai kemiripan tertinggi dengan pengguna target. Kolom nilai kemiripan menunjukkan kemiripan antar pengguna. Semakin tinggi nilainya, semakin besar kesamaan preferensi mereka. Biasanya, nilai *cosine similarity* mendekati 1 menunjukkan bahwa dua pengguna memiliki kesamaan preferensi yang tinggi. Pemilihan pengguna dengan kemiripan tertinggi kemudian digunakan untuk menentukan restoran mana yang mungkin akan disukai oleh pengguna target.

Selanjutnya, pencarian prediksi berdasarkan nilai kemiripan yang telah dihitung dilakukan menggunakan metode *weighted average*. Dalam konteks ini, rating dari pengguna yang mirip akan diberikan bobot lebih tinggi saat melakukan prediksi, untuk memastikan bahwa rekomendasi lebih relevan dengan preferensi pengguna target. Perhitungan *weighted average* dapat dilihat pada contoh berikut:

Prediksi untuk R00076:

$$weighted\ avg = \frac{17.8412}{4.328} = 4.122$$

Prediksi untuk R00089:

$$weighted\ avg = \frac{20.7281}{4.328} = 4.789$$

Prediksi untuk R00047:

$$weighted\ avg = \frac{16.9003}{4.328} = 3.905$$

Prediksi untuk R00101:

$$weighted\ avg = \frac{19.3601}{4.328} = 4.473$$

Prediksi untuk R00012:

$$weighted\ avg = \frac{16.4392}{4.328} = 3.798$$

Setelah hasil prediksi didapatkan, langkah terakhir adalah membuat rekomendasi dengan menampilkan hasil prediksiurut dari yang teratas. Tabel 6 menunjukkan 10 restoran terbaik berdasarkan hasil algoritma.

Tabel 6. Hasil rekomendasi restoran

Id restoran	Nama restoran
R00089	Warong Legong
R00101	Opia Bali
R00076	Casa Tua Canggu
R00047	Pizza Hut Delivery - PHD Kerobokan Bali
R00012	Warung Modus
R00125	Pizza Fabbrica Canggu
R00091	Piasan Restaurant
R00072	JI Restaurant Bali
R00131	X.O Suki & Cuisine
R00117	Boneka Restaurant

Berdasarkan hasil rekomendasi, restoran dengan id R00089 yaitu Warong Legong menduduki peringkat pertama dengan nilai prediksi sebesar 4.789. Di posisi kedua, Opia Bali memperoleh nilai prediksi 4.473, diikuti oleh Casa Tua Canggu di peringkat ketiga dengan nilai prediksi 4.122. Rekomendasi ini diharapkan dapat memberikan saran yang relevan dan bermanfaat bagi pengguna target, membantu mereka dalam memilih restoran berdasarkan preferensi yang paling sesuai dengan pola penilaian mereka.

2. Evaluasi

Setelah proses rekomendasi selesai, selanjutnya adalah melakukan evaluasi. Pada penelitian ini, RMSE digunakan untuk evaluasi. RMSE merupakan metrik yang tepat karena mengukur perbedaan antara nilai prediksi dan nilai aktual, memberikan gambaran tentang sejauh mana model dapat memprediksi dengan tepat. Hasil evaluasi menggunakan RMSE ditunjukkan pada persamaan berikut:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum (P_i - r_i)^2} = 0.553048$$

Nilai RMSE yang diperoleh, yaitu 0.553, tergolong rendah, menunjukkan bahwa model memiliki akurasi yang baik dalam memprediksi preferensi pengguna. Nilai ini menunjukkan bahwa perbedaan antara prediksi dan nilai aktual relatif kecil. Dengan demikian, model ini dapat diandalkan untuk memberikan rekomendasi yang sesuai dengan preferensi pengguna.

KESIMPULAN DAN SARAN

Penelitian ini mengembangkan sistem rekomendasi restoran halal dengan metode *hybrid* yang menggabungkan *collaborative filtering* dan *autoencoder*. Sistem ini ditujukan untuk membantu masyarakat Muslim menemukan restoran halal di daerah wisata dengan mayoritas penduduk non-Muslim. *Cosine similarity* digunakan untuk menghitung kemiripan antar pengguna, sementara *autoencoder* menangkap fitur penting dari data, menghasilkan rekomendasi yang lebih akurat dan relevan.

Evaluasi dengan RMSE menunjukkan tingkat kesalahan yang rendah, menandakan rekomendasi sesuai dengan preferensi pengguna. Kombinasi metode *collaborative filtering* dan *autoencoder* terbukti meningkatkan akurasi dan relevansi sistem. Namun, kurangnya data mempengaruhi hasil rekomendasi. Sistem ini dapat menjadi dasar pengembangan lebih lanjut untuk sistem rekomendasi restoran halal di masa depan.

DAFTAR PUSTAKA

- [1] Busch, P. A., Hausvik, G. I., Ropstad, O. K., & Pettersen, D. (2021). Smartphone usage among older adults. *Computers in Human Behavior*, 121(March), doi: 10.1016/j.chb.2021.106783
- [2] García-Sánchez, F., Colomo-Palacios, R., & Valencia-García, R. (2020). A social-semantic recommender system for advertisements. *Information Processing and Management*, 57(2), 102153, doi: 10.1016/j.ipm.2019.102153
- [3] Ajaegbu, C. (2021). An optimized item-based collaborative filtering algorithm. *Journal of Ambient Intelligence and Humanized Computing*, 12(12), 10629–10636, doi: 10.1007/s12652-020-02876-1
- [4] Chassagnon, G., Vakalopoulou, M., Paragios, N., & Revel, M. P. (2020). Deep learning: definition and perspectives for thoracic imaging. *European Radiology*, 30(4), 2021–2030, doi: 10.1007/s00330-019-06564-3
- [5] Jin, Y., Zhao, H., Liu, M., Zhu, Y., Du, L., Gao, L., & Buntine, W. (2020). Leveraging Cross Feedback of User and Item Embeddings with Attention for Variational Autoencoder based Collaborative Filtering. <http://arxiv.org/abs/2002.09145>
- [6] Nurhayati, S. D., & Widayani, W. (2021). Sistem Rekomendasi Wisata Kuliner di Yogyakarta dengan Metode Item-Based Collaborative Filtering. 1(2), 55–63.
- [7] Nasy'an Taufiq Al Ghifari, Benhard Sitohang, & Gusti Ayu Putri Saptawati. (2021). Addressing Cold Start New User in Recommender System Based on Hybrid Approach: A review and bibliometric analysis. *IT Journal Research and Development*, 6(1), 1–16, doi: 10.25299/itjrd.2021.vol6(1).6118
- [8] Strub, F., Gaudel, R., & Mary, J. (2016). Hybrid recommender system based on autoencoders. *ACM International Conference Proceeding Series*, 15-September-2016, 11–16, doi: 10.1145/2988450.2988456
- [9] Singh, K., Mishra, M., & Singh, E. S. (2024). Content-based Recommender System Using Cosine Similarity. *International Journal for Research in Applied Science and Engineering Technology*, 12(5), 2541–2548, doi: 10.22214/ijraset.2024.61835
- [10] Bank, D., Koenigstein, N., & Giryas, R. (2023). Autoencoders. *Machine Learning for Data Science Handbook: Data Mining and Knowledge Discovery Handbook*, Third Edition, 353–374, doi: 10.1007/978-3-031-24628-9_16
- [11] Ferreira, D., Silva, S., Abelha, A., & Machado, J. (2020). Recommendation system using autoencoders. *Applied Sciences (Switzerland)*, 10(16), 1–17, doi: 10.3390/app10165510
- [12] Martins, G. B., Papa, J. P., & Adeli, H. (2020). Deep learning techniques for recommender systems based on collaborative filtering. *Expert Systems*, 37(6), 1–21, doi: 10.1111/exsy.12647
- [13] Mana, S. C., & Sasipraba, T. (2021). Research on cosine similarity and pearson correlation based recommendation models. *Journal of Physics: Conference Series*, 1770(1), doi: 10.1088/1742-6596/1770/1/012014
- [14] Salloum, S., & Rajamanthri, D. (2021). Implementation and evaluation of movie recommender systems using collaborative filtering. *Journal of Advances in Information Technology*, 12(3), 189–196, doi: 10.12720/jait.12.3.189-196
- [15] Ahmed, E., & Letta, A. (2023). Book Recommendation Using Collaborative Filtering Algorithm. *Applied Computational Intelligence and Soft Computing*, 2023, doi: 10.1155/2023/1514801