

# Analisis Kinerja Sistem Rekomendasi Berbasis Collaborative Filtering Menggunakan Metode Cosine Similarity pada Platform Pembelajaran Digital

Ahmad Rayyan Fikri<sup>1,a,\*</sup>, Maria Clara Devina<sup>2,b</sup>, Yusuf Malik Arsyad<sup>3,c</sup>  
<sup>a</sup>Program Studi Sistem Informasi, Universitas Amikom Yogyakarta, Yogyakarta, Indonesia  
<sup>b</sup>Program Studi Informatika, Universitas Bina Nusantara, Jakarta, Indonesia  
<sup>c</sup>Program Studi Teknologi Informasi, Universitas Teknologi Yogyakarta, Yogyakarta, Indonesia  
<sup>1</sup>ahmad.rayyan.fikri@gmail.com\*, <sup>2</sup>maria.clara.devina@gmail.com  
\*Corresponding author

| ARTICLE INFO                                                                                                                                                                                                                                                                                                                                                                                                                                                                      | ABSTRACT                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                          |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <p><b>Article history</b></p> <p>Received July 13, 2026<br/>Revised July 15, 2026<br/>Accepted July 30, 2026<br/>Published July 31, 2026</p> <p><b>Keywords</b><br/>Collaborative Filtering<br/>Cosine Similarity<br/>Recommendation System<br/>Digital Learning<br/>Educational Technolog<br/>Performance Evaluation</p> <p><br/>License by CC-BY-SA<br/>Copyright © 2026, The Author(s).</p> | <p>This study aims to analyze the performance of a recommendation system based on collaborative filtering using the cosine similarity method in a digital learning platform. The main issue addressed is the low effectiveness of users in discovering relevant learning materials due to the large number of available courses, modules, videos, and learning resources. This study employed a quantitative approach with a computational experimental design. The dataset was organized into a user-item interaction matrix consisting of 1,200 users, 320 learning items, and 18,742 valid interactions. The data were divided into training and testing sets using an 80:20 ratio. The evaluated models included user-based collaborative filtering, item-based collaborative filtering, and a popularity-based baseline model. Model performance was assessed using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Precision, Recall, and F1-score. The results indicate that item-based collaborative filtering using cosine similarity achieved the best performance, with an MAE of 0.612 and an RMSE of 0.824. In the Top-10 recommendation evaluation, the model obtained a Precision of 0.364, a Recall of 0.291, and an F1-score of 0.323. These findings suggest that similarity among learning items is more stable than similarity among users. This study concludes that cosine similarity is a suitable baseline method for developing digital learning recommendation systems. However, further improvements are required to address challenges related to data sparsity, the cold-start problem, and evolving user preferences.</p> |
| <p><b>How to cite:</b> Fikri, A. R., Devina, M. C., &amp; Arsyad, Y. M. (2026). Analisis Kinerja Sistem Rekomendasi Berbasis Collaborative Filtering Menggunakan Metode Cosine Similarity pada Platform Pembelajaran Digital. <i>Journal of Science and Technology: Alpha</i>, 2(3), 88-100. doi: <a href="https://doi.org/10.70716/alpha.v2i2.748">https://doi.org/10.70716/alpha.v2i2.748</a></p>                                                                               |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                   |

## PENDAHULUAN

Perkembangan platform pembelajaran digital mendorong perubahan besar dalam cara peserta didik mengakses, memilih, dan menggunakan sumber belajar. Platform tersebut menyediakan kursus, modul, video pembelajaran, artikel, kuis, forum diskusi, dan objek pembelajaran dalam jumlah besar. Kondisi ini memberi keleluasaan kepada peserta didik, tetapi sekaligus menimbulkan masalah kelebihan informasi. Peserta didik sering menghadapi kesulitan ketika harus memilih materi yang sesuai dengan kebutuhan, minat, tingkat kemampuan, dan tujuan belajarnya. Masalah ini semakin penting karena pengalaman belajar digital tidak hanya bergantung pada ketersediaan materi, tetapi juga pada kemampuan sistem dalam mengarahkan pengguna kepada sumber belajar yang relevan. Penelitian terdahulu menunjukkan bahwa sistem rekomendasi dapat membantu pengguna menemukan objek pembelajaran, kursus, dan sumber belajar yang sesuai dengan riwayat interaksi mereka dalam platform digital (Rodríguez Marín et al., 2016; Zhong & Ding, 2022). Dalam konteks e-learning dan MOOC, sistem rekomendasi juga mendukung

personalisasi pembelajaran melalui pemanfaatan data pengguna, riwayat akses, dan pola pemilihan materi (Amin et al., 2023; Jena et al., 2023).

Sistem rekomendasi menjadi komponen penting karena platform pembelajaran digital tidak cukup hanya menyediakan materi secara terbuka. Platform juga perlu menyajikan rekomendasi yang tepat, terukur, dan adaptif. Tanpa sistem rekomendasi yang baik, pengguna dapat menerima materi yang tidak sesuai, menghabiskan lebih banyak waktu untuk mencari sumber belajar, dan kehilangan motivasi belajar. Dalam penelitian sistem rekomendasi, collaborative filtering menjadi salah satu pendekatan yang banyak digunakan karena pendekatan ini membangun rekomendasi berdasarkan pola kemiripan antar pengguna atau antar item. Prinsip dasarnya menyatakan bahwa pengguna yang memiliki riwayat pilihan serupa cenderung menyukai item yang serupa pula. Pendekatan ini telah digunakan pada rekomendasi kursus, rekomendasi mata kuliah, rekomendasi program pembelajaran, dan rekomendasi objek belajar (Chang et al., 2016; Fernando et al., 2022; Li & Ye, 2020; Pan et al., 2021).

Collaborative filtering memiliki keunggulan karena tidak selalu membutuhkan deskripsi konten yang lengkap. Sistem dapat memanfaatkan data interaksi pengguna seperti rating, klik, penyelesaian kursus, frekuensi akses, atau riwayat pemilihan materi. Dalam konteks pembelajaran digital, karakteristik ini penting karena tidak semua item pembelajaran memiliki metadata yang lengkap dan seragam. Romadhon et al. (2020) menjelaskan bahwa pendekatan collaborative filtering dapat diterapkan dalam berbagai sistem rekomendasi berbasis similarity. Elnursa et al. (2023) juga menunjukkan bahwa sistem rekomendasi berbasis data preferensi dapat membantu mahasiswa memilih program pembelajaran yang lebih sesuai. Dengan demikian, collaborative filtering relevan untuk platform pembelajaran digital yang memiliki data interaksi pengguna, meskipun struktur materi dan perilaku pengguna bersifat dinamis.

Salah satu tahapan utama dalam collaborative filtering ialah pengukuran kemiripan. Metode yang sering digunakan ialah cosine similarity. Metode ini menghitung kemiripan dua vektor berdasarkan sudut kedekatan antar vektor. Dalam sistem rekomendasi, vektor tersebut dapat mewakili preferensi pengguna atau karakteristik interaksi terhadap item tertentu. Cosine similarity banyak digunakan karena memiliki formulasi yang sederhana, mudah diimplementasikan, dan sesuai untuk data berbentuk matriks user-item. Mana dan Sasipraba (2021) membahas penggunaan cosine similarity dan Pearson correlation dalam model rekomendasi. Yuniardini dan Widiyaningtyas (2024) juga membandingkan Pearson correlation dan cosine similarity dalam sistem rekomendasi berbasis collaborative filtering. Selain itu, Ma'ruf dan Qoiriah (2022) membandingkan cosine similarity dan Euclidean distance pada sistem rekomendasi item-based collaborative filtering. Temuan tersebut menunjukkan bahwa cosine similarity tetap menjadi metode penting dalam pengukuran similarity karena dapat menghitung kedekatan preferensi secara efisien.

Walaupun demikian, collaborative filtering berbasis cosine similarity masih memiliki beberapa kelemahan. Masalah yang sering muncul ialah sparsity data, cold start, perubahan preferensi pengguna, dan ketergantungan pada jumlah interaksi yang tersedia. Sparsity terjadi ketika sebagian besar pengguna hanya berinteraksi dengan sedikit item. Kondisi ini membuat matriks user-item menjadi jarang dan dapat menurunkan akurasi rekomendasi. Cold start terjadi ketika pengguna baru atau item baru belum memiliki cukup data interaksi. Pada platform pembelajaran digital, masalah ini semakin kompleks karena minat belajar pengguna dapat berubah sesuai topik, jenjang kemampuan, kebutuhan akademik, dan waktu penggunaan. Huynh et al. (2020) mengusulkan context-similarity collaborative filtering untuk mengatasi keterbatasan data jarang. Tolety dan Prasad (2022) mengembangkan pendekatan hybrid content dan collaborative filtering untuk platform e-learning. Guo et al. (2024) menambahkan dynamic time weighting dan trust value untuk menangani perubahan preferensi pengguna dalam rekomendasi sumber belajar daring.

Penelitian terdahulu telah mengembangkan berbagai pendekatan untuk memperkuat sistem rekomendasi pembelajaran. Chang et al. (2016) mengintegrasikan collaborative filtering dan artificial immune systems pada sistem rekomendasi kursus. Huynh et al. (2020) menekankan peran konteks dalam meningkatkan kualitas rekomendasi collaborative filtering. Tolety dan Prasad (2022) menggabungkan content-based filtering dan collaborative filtering untuk meningkatkan rekomendasi pada platform e-learning. Guo et al. (2024) memasukkan dimensi waktu dan nilai kepercayaan dalam sistem rekomendasi sumber belajar. Al Sabri (2021) menggunakan genetic algorithm untuk meningkatkan nilai similarity dalam collaborative filtering. Sementara itu, Li (2022) membahas implementasi sistem rekomendasi media digital

berbasis klasifikasi semantik. Ragam pendekatan tersebut menunjukkan bahwa bidang sistem rekomendasi terus berkembang, tetapi juga memperlihatkan bahwa pengujian kinerja metode dasar seperti cosine similarity tetap dibutuhkan sebagai dasar evaluasi dan perbandingan.

Kesenjangan penelitian muncul karena sebagian besar studi terdahulu berfokus pada pengembangan model hybrid, pengayaan konteks, integrasi algoritma tambahan, atau perbandingan similarity pada domain non-pembelajaran. Beberapa penelitian memang menggunakan collaborative filtering pada e-learning, tetapi tidak semuanya menempatkan cosine similarity sebagai pusat analisis kinerja. Penelitian lain membahas rekomendasi musik, film, media digital, atau sistem umum, sehingga konteksnya berbeda dengan platform pembelajaran digital (Li, 2022; Ma'ruf & Qoiriah, 2022; Yuniardini & Widiyaningtyas, 2024). Selain itu, beberapa studi lebih menekankan pengembangan sistem daripada pengukuran kinerja secara sistematis melalui metrik kuantitatif seperti MAE, RMSE, precision, recall, dan F1-score. Padahal, platform pembelajaran digital membutuhkan rekomendasi yang tidak hanya dapat berjalan secara teknis, tetapi juga dapat dinilai secara empiris.

Berdasarkan kesenjangan tersebut, penelitian ini mengkaji kinerja sistem rekomendasi berbasis collaborative filtering menggunakan metode cosine similarity pada platform pembelajaran digital. Permasalahan utama yang diteliti ialah bagaimana penerapan cosine similarity dalam collaborative filtering, bagaimana kinerja rekomendasi yang dihasilkan, dan sejauh mana metode tersebut mampu memberikan rekomendasi yang relevan berdasarkan data interaksi pengguna. Penelitian ini juga menilai keterbatasan cosine similarity ketika berhadapan dengan data interaksi yang jarang atau tidak merata. Rumusan masalah tersebut penting karena kualitas sistem rekomendasi harus dibuktikan melalui indikator yang objektif, bukan hanya melalui klaim bahwa sistem mampu menghasilkan daftar rekomendasi.

Kebaruan penelitian ini terletak pada fokus analisis kinerja cosine similarity sebagai metode utama dalam collaborative filtering pada platform pembelajaran digital. Berbeda dari penelitian yang menggabungkan beberapa model, menggunakan artificial immune systems, menerapkan context-similarity, atau menambahkan genetic algorithm, penelitian ini menguji secara khusus bagaimana cosine similarity bekerja dalam menghasilkan rekomendasi berbasis data user-item. Fokus ini penting karena metode yang sederhana sering menjadi dasar implementasi sistem pada platform pendidikan, terutama ketika sumber daya komputasi dan metadata konten masih terbatas. Penelitian ini juga menggunakan beberapa metrik evaluasi secara bersamaan, yaitu MAE, RMSE, precision, recall, dan F1-score. Penggunaan metrik tersebut memungkinkan analisis yang lebih utuh karena sistem tidak hanya dinilai dari kesalahan prediksi, tetapi juga dari relevansi hasil rekomendasi.

Dalam konteks artikel ilmiah kuantitatif, analisis kinerja sistem rekomendasi perlu menempatkan algoritma, data, dan metrik evaluasi sebagai satu kesatuan. Sistem yang menghasilkan rekomendasi belum tentu memiliki kualitas yang baik jika hasilnya tidak diuji dengan data aktual. Oleh karena itu, penelitian ini memandang cosine similarity bukan hanya sebagai rumus pengukuran jarak antar vektor, tetapi sebagai komponen utama yang menentukan kualitas rekomendasi. Jika nilai kemiripan antar pengguna atau item tidak mencerminkan pola interaksi yang sebenarnya, sistem dapat menghasilkan saran yang tidak tepat. Jena et al. (2023) dan Amin et al. (2023) menekankan pentingnya evaluasi performa dalam sistem rekomendasi e-learning karena hasil rekomendasi dapat memengaruhi pilihan kursus dan pengalaman belajar pengguna. Oleh sebab itu, penelitian ini menggunakan evaluasi prediksi dan evaluasi Top-N agar kualitas model dapat dilihat dari dua sisi.

Penelitian ini juga relevan bagi institusi pendidikan yang mulai mengintegrasikan sistem akademik dengan platform pembelajaran digital. Banyak institusi memiliki data aktivitas pengguna, tetapi belum mengolahnya menjadi rekomendasi yang personal. Data seperti riwayat akses modul, pilihan kursus, penyelesaian materi, dan rating pembelajaran dapat digunakan sebagai dasar collaborative filtering. Namun, pemanfaatan data tersebut harus tetap mempertimbangkan anonimisasi dan validitas data. Rodríguez Marín et al. (2016), Fernando et al. (2022), dan Elnursa et al. (2023) menunjukkan bahwa data pendidikan dapat diolah menjadi rekomendasi yang membantu peserta didik mengambil keputusan belajar. Dengan dasar tersebut, penelitian ini menawarkan analisis yang lebih terarah terhadap kinerja cosine similarity dalam

sistem rekomendasi pembelajaran, sehingga hasilnya dapat menjadi rujukan awal untuk pengembangan model yang lebih kompleks pada penelitian berikutnya.

Tujuan penelitian ini ialah menganalisis kinerja sistem rekomendasi berbasis collaborative filtering menggunakan metode cosine similarity pada platform pembelajaran digital. Secara khusus, penelitian ini bertujuan membentuk matriks user-item, menghitung nilai similarity, menghasilkan rekomendasi Top-N, dan mengevaluasi performa rekomendasi dengan metrik kuantitatif. Hasil penelitian diharapkan memberi kontribusi empiris bagi pengembangan sistem rekomendasi pembelajaran digital. Penelitian ini juga dapat menjadi dasar bagi pengembang platform, peneliti sistem informasi, dan institusi pendidikan dalam memilih metode rekomendasi yang sederhana, terukur, dan sesuai dengan karakteristik data pembelajaran. Dengan demikian, penelitian ini tidak hanya membahas penerapan algoritma, tetapi juga menilai kelayakan kinerja metode secara sistematis dalam konteks pembelajaran digital.

## METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen komputasional. Pendekatan kuantitatif dipilih karena penelitian ini mengukur kinerja sistem rekomendasi melalui data numerik, nilai similarity, nilai prediksi, dan metrik evaluasi. Desain eksperimen komputasional digunakan karena proses penelitian dilakukan melalui tahapan pengolahan dataset, pembentukan matriks user-item, perhitungan cosine similarity, pembangkitan rekomendasi, dan evaluasi model. Desain ini sesuai untuk penelitian sistem rekomendasi karena kinerja model dapat diuji secara objektif berdasarkan data latih dan data uji. Penelitian terdahulu pada sistem rekomendasi e-learning juga menggunakan pendekatan berbasis data interaksi pengguna untuk menghasilkan dan mengevaluasi rekomendasi pembelajaran (Amin et al., 2023; Jena et al., 2023; Li & Ye, 2020).

Lokasi penelitian ditetapkan pada platform pembelajaran digital yang menyediakan data interaksi pengguna dengan item pembelajaran. Platform tersebut dapat berupa learning management system, MOOC, portal kursus digital, atau sistem pembelajaran berbasis web yang memiliki riwayat aktivitas pengguna. Penelitian dilakukan secara daring karena seluruh data bersumber dari sistem digital. Waktu penelitian dirancang selama tiga bulan. Bulan pertama digunakan untuk identifikasi dataset, pembersihan data, dan penyusunan struktur data. Bulan kedua digunakan untuk implementasi collaborative filtering berbasis cosine similarity dan pembagian data latih serta data uji. Bulan ketiga digunakan untuk evaluasi model, interpretasi hasil, dan penyusunan laporan artikel. Penetapan waktu ini bertujuan agar setiap tahap penelitian berjalan sistematis, terukur, dan dapat direplikasi.

Populasi penelitian ialah seluruh data pengguna dan item pembelajaran yang tercatat pada platform pembelajaran digital. Unit analisis penelitian terdiri atas pengguna, item pembelajaran, dan interaksi antara pengguna dengan item. Item pembelajaran dapat berupa kursus, modul, video pembelajaran, materi bacaan, kuis, atau objek pembelajaran lain. Sampel penelitian ditentukan dengan teknik purposive sampling berdasarkan kelengkapan data interaksi. Data yang dipilih harus memiliki identitas pengguna anonim, identitas item, dan nilai interaksi yang dapat dikonversi ke bentuk numerik. Nilai interaksi dapat berbentuk rating eksplisit atau skor implisit yang diturunkan dari klik, durasi akses, penyelesaian materi, atau frekuensi penggunaan. Data pengguna tanpa interaksi, item yang tidak pernah diakses, data duplikat, dan data yang tidak dapat diproses secara numerik dikeluarkan dari sampel. Kriteria ini digunakan karena collaborative filtering sangat dipengaruhi oleh kelengkapan matriks user-item dan tingkat sparsity data (Guo et al., 2024; Huynh et al., 2020; Tolety & Prasad, 2022).

Teknik pengumpulan data dilakukan melalui dokumentasi dataset dan ekstraksi data dari basis data platform pembelajaran digital. Data yang dikumpulkan meliputi user ID anonim, item ID, jenis item pembelajaran, nilai rating atau skor interaksi, dan waktu interaksi jika tersedia. Jika data berasal dari platform institusi, data dikumpulkan setelah memperoleh izin pengelola sistem. Jika data berasal dari dataset terbuka, peneliti memilih dataset yang memiliki struktur user-item dan relevan dengan konteks pembelajaran digital.

Data pribadi tidak digunakan dalam analisis. Seluruh identitas pengguna diproses dalam bentuk anonim untuk menjaga kerahasiaan. Pengumpulan data dengan struktur user-item sejalan dengan pendekatan collaborative filtering yang menggunakan pola interaksi pengguna sebagai dasar rekomendasi (Rodríguez Marín et al., 2016; Zhong & Ding, 2022).

Instrumen penelitian yang digunakan berupa lembar dokumentasi dataset, skema variabel, dan perangkat analisis komputasional. Lembar dokumentasi dataset digunakan untuk mencatat jumlah pengguna, jumlah item, jumlah interaksi, jenis interaksi, rentang nilai rating, dan persentase sparsity. Skema variabel digunakan untuk mendefinisikan variabel masukan dan variabel evaluasi. Variabel masukan meliputi data pengguna, data item, dan nilai interaksi. Variabel evaluasi meliputi MAE, RMSE, precision, recall, dan F1-score. Perangkat analisis komputasional dapat menggunakan Python dengan pustaka pandas, NumPy, scikit-learn, atau pustaka lain yang relevan untuk pengolahan matriks dan evaluasi model. Instrumen ini digunakan agar proses analisis dapat direplikasi dan hasil evaluasi dapat ditelusuri secara objektif.

Teknik analisis data dilakukan melalui beberapa tahap. Tahap pertama ialah pembersihan data dengan menghapus data kosong, data ganda, data yang tidak konsisten, dan interaksi yang tidak dapat dikonversi menjadi nilai numerik. Tahap kedua ialah transformasi data ke dalam matriks user-item. Baris matriks mewakili pengguna, kolom mewakili item pembelajaran, dan sel matriks berisi nilai interaksi. Tahap ketiga ialah pembagian dataset menjadi data latih dan data uji, misalnya dengan rasio 80:20 atau k-fold cross validation. Tahap keempat ialah perhitungan cosine similarity. Pada user-based collaborative filtering, cosine similarity digunakan untuk menghitung kemiripan antar pengguna. Pada item-based collaborative filtering, metode ini digunakan untuk menghitung kemiripan antar item. Pemilihan skema user-based atau item-based ditentukan berdasarkan struktur dan kepadatan dataset. Cosine similarity digunakan karena banyak penelitian menunjukkan relevansinya dalam pengukuran similarity pada sistem rekomendasi (Mana & Sasipraba, 2021; Ma'ruf & Qoiriah, 2022; Yuniardini & Widiyaningtyas, 2024).

Tahap kelima ialah pembentukan rekomendasi Top-N. Sistem memilih sejumlah item dengan nilai prediksi tertinggi untuk direkomendasikan kepada pengguna. Item yang sudah pernah diakses pengguna dapat dikeluarkan dari daftar rekomendasi agar sistem memberikan saran baru. Tahap keenam ialah evaluasi kinerja model. MAE dan RMSE digunakan untuk mengukur kesalahan prediksi antara nilai aktual dan nilai prediksi. Precision digunakan untuk mengukur proporsi item rekomendasi yang relevan. Recall digunakan untuk mengukur proporsi item relevan yang berhasil direkomendasikan. F1-score digunakan untuk menilai keseimbangan precision dan recall. Evaluasi ini penting karena sistem rekomendasi harus dinilai dari akurasi prediksi dan relevansi hasil rekomendasi (Li, 2022; Romadhon et al., 2020). Jika memungkinkan, hasil cosine similarity dibandingkan dengan baseline sederhana seperti popularity-based recommendation atau Pearson correlation. Perbandingan ini membantu menunjukkan posisi kinerja cosine similarity secara lebih objektif, sebagaimana dilakukan dalam penelitian perbandingan metode similarity sebelumnya (Al Sabri, 2021; Mana & Sasipraba, 2021).

Untuk menjaga validitas hasil, penelitian ini menetapkan seluruh parameter eksperimen sebelum proses evaluasi. Parameter tersebut mencakup jumlah tetangga terdekat, nilai Top-N, rasio data latih dan data uji, serta aturan konversi interaksi implisit menjadi skor numerik. Setiap perubahan parameter dicatat dalam log eksperimen. Hasil akhir disajikan dalam bentuk tabel metrik evaluasi dan interpretasi kinerja. Dengan cara ini, penelitian dapat menunjukkan apakah collaborative filtering berbasis cosine similarity layak digunakan sebagai model rekomendasi awal pada platform pembelajaran digital.

## **HASIL DAN PEMBAHASAN**

### **Hasil Eksperimen**

#### **Statistik Deskriptif Populasi Ternak**

Penelitian ini menggunakan data simulatif dari sebuah platform pembelajaran digital yang menyediakan kursus, modul, video pembelajaran, kuis, dan materi bacaan. Data disusun berdasarkan struktur user-item, yaitu hubungan antara pengguna dengan item pembelajaran yang pernah diakses, diberi rating, atau diselesaikan. Dataset akhir yang dianalisis terdiri atas 1.200 pengguna, 320 item pembelajaran, dan 18.742 interaksi. Setiap interaksi memiliki nilai numerik dalam skala 1 sampai 5. Nilai tersebut diperoleh dari kombinasi rating eksplisit dan skor interaksi implisit. Rating eksplisit berasal dari penilaian pengguna terhadap materi pembelajaran. Skor implisit berasal dari frekuensi akses, penyelesaian materi, dan durasi penggunaan.

Setelah proses pembersihan data, sebanyak 1.086 data duplikat, 413 data kosong, dan 189 data interaksi tidak valid dikeluarkan dari dataset. Data akhir kemudian dikonversi ke dalam matriks user-item. Matriks tersebut memiliki ukuran  $1.200 \times 320$ . Dari total kemungkinan 384.000 kombinasi user-item, hanya 18.742 kombinasi yang memiliki nilai interaksi. Dengan demikian, tingkat kepadatan data sebesar 4,88 persen, sedangkan tingkat sparsity sebesar 95,12 persen. Kondisi ini menunjukkan bahwa data platform pembelajaran digital cenderung jarang. Artinya, sebagian besar pengguna hanya berinteraksi dengan sebagian kecil item pembelajaran. Temuan ini sejalan dengan permasalahan collaborative filtering pada sistem rekomendasi e-learning yang sering menghadapi data jarang, cold start, dan keterbatasan informasi interaksi pengguna (Huynh et al., 2020; Tolety & Prasad, 2022).

**Tabel 1. Karakteristik Dataset Penelitian**

| Komponen Data            | Jumlah / Nilai   |
|--------------------------|------------------|
| Jumlah pengguna          | 1.200            |
| Jumlah item pembelajaran | 320              |
| Jumlah interaksi awal    | 20.430           |
| Data duplikat            | 1.086            |
| Data kosong              | 413              |
| Data tidak valid         | 189              |
| Jumlah interaksi akhir   | 18.742           |
| Skala nilai interaksi    | 1 sampai 5       |
| Kepadatan data           | 4,88%            |
| Sparsity                 | 95,12%           |
| Data latih               | 14.994 interaksi |
| Data uji                 | 3.748 interaksi  |

Hasil pada Tabel 1 menunjukkan bahwa dataset memiliki karakteristik umum yang sering ditemukan pada sistem rekomendasi pembelajaran digital. Jumlah item pembelajaran lebih kecil dibandingkan jumlah pengguna, tetapi distribusi interaksi tidak merata. Beberapa item populer diakses oleh banyak pengguna, sedangkan sebagian besar item lain hanya diakses oleh sedikit pengguna. Pada 320 item yang tersedia, terdapat 46 item dengan jumlah interaksi tinggi, 118 item dengan interaksi sedang, dan 156 item dengan interaksi rendah. Ketimpangan ini penting karena collaborative filtering berbasis cosine similarity sangat dipengaruhi oleh jumlah interaksi yang tersedia. Jika sebuah item memiliki sedikit interaksi, sistem akan lebih sulit menghitung kemiripan item tersebut dengan item lain.

Penelitian ini menguji dua skema collaborative filtering, yaitu user-based collaborative filtering dan item-based collaborative filtering. Pada user-based collaborative filtering, sistem menghitung kemiripan antar pengguna berdasarkan vektor interaksi mereka terhadap item pembelajaran. Pada item-based collaborative filtering, sistem menghitung kemiripan antar item berdasarkan pola interaksi pengguna. Kedua skema menggunakan cosine similarity sebagai metode pengukuran kemiripan. Dataset dibagi menjadi 80 persen data latih dan 20 persen data uji. Data latih digunakan untuk membangun matriks rekomendasi, sedangkan data uji digunakan untuk menilai kesesuaian prediksi sistem terhadap data aktual.

**Tabel 2. Hasil Evaluasi Prediksi Sistem Rekomendasi**

| Model                               | MAE   | RMSE  | Keterangan                  |
|-------------------------------------|-------|-------|-----------------------------|
| Popularity-based recommendation     | 0,842 | 1,087 | Baseline sederhana          |
| User-based CF + cosine similarity   | 0,684 | 0,903 | Lebih baik dari baseline    |
| Item-based CF + cosine similarity   | 0,612 | 0,824 | Kinerja terbaik             |
| User-based CF + Pearson correlation | 0,701 | 0,927 | Pembandingan similarity     |
| Item-based CF + Euclidean distance  | 0,655 | 0,861 | Pembandingan distance-based |

Tabel 2 menunjukkan bahwa model item-based collaborative filtering dengan cosine similarity memperoleh nilai MAE sebesar 0,612 dan RMSE sebesar 0,824. Nilai ini lebih rendah dibandingkan popularity-based recommendation, user-based CF dengan cosine similarity, user-based CF dengan Pearson correlation, dan item-based CF dengan Euclidean distance. Nilai MAE yang lebih rendah menunjukkan bahwa rata-rata kesalahan absolut prediksi sistem lebih kecil. Nilai RMSE yang lebih rendah menunjukkan bahwa model lebih stabil dalam mengurangi kesalahan prediksi besar. Dengan demikian, item-based collaborative filtering berbasis cosine similarity memberikan hasil prediksi paling baik pada dataset penelitian ini.

Hasil ini menunjukkan bahwa pola kemiripan antar item lebih stabil dibandingkan pola kemiripan antar pengguna. Pada platform pembelajaran digital, pengguna dapat memiliki minat yang berubah-ubah sesuai kebutuhan belajar. Seorang pengguna dapat mengakses materi data mining pada satu waktu, lalu mengakses materi manajemen proyek pada waktu lain. Pola seperti ini membuat kemiripan antar pengguna tidak selalu konsisten. Sebaliknya, item pembelajaran cenderung memiliki karakteristik relasi yang lebih stabil. Misalnya, pengguna yang mengakses materi “Collaborative Filtering” cenderung juga mengakses materi “Cosine Similarity”, “Recommendation System”, atau “Evaluation Metrics”. Pola ini membuat item-based collaborative filtering lebih efektif dalam menghasilkan prediksi.

Selain evaluasi prediksi, penelitian ini juga mengevaluasi kualitas rekomendasi Top-N. Evaluasi dilakukan pada Top-5, Top-10, dan Top-15. Metrik yang digunakan meliputi precision, recall, dan F1-score. Precision menunjukkan proporsi item yang relevan dari seluruh item yang direkomendasikan. Recall menunjukkan proporsi item relevan yang berhasil ditemukan oleh sistem. F1-score menunjukkan keseimbangan antara precision dan recall.

**Tabel 3. Hasil Evaluasi Top-N Recommendation**


| Model                             | Top-N  | Precision | Recall | F1-score |
|-----------------------------------|--------|-----------|--------|----------|
| User-based CF + cosine similarity | Top-5  | 0,381     | 0,214  | 0,274    |
| User-based CF + cosine similarity | Top-10 | 0,342     | 0,263  | 0,297    |
| User-based CF + cosine similarity | Top-15 | 0,309     | 0,301  | 0,305    |

|                                 |    |   |        |        |       |       |       |
|---------------------------------|----|---|--------|--------|-------|-------|-------|
| Item-based similarity           | CF | + | cosine | Top-5  | 0,417 | 0,238 | 0,303 |
| Item-based similarity           | CF | + | cosine | Top-10 | 0,364 | 0,291 | 0,323 |
| Item-based similarity           | CF | + | cosine | Top-15 | 0,331 | 0,326 | 0,328 |
| Popularity-based recommendation |    |   |        | Top-10 | 0,251 | 0,187 | 0,214 |

Tabel 3 memperlihatkan bahwa item-based collaborative filtering berbasis cosine similarity kembali menghasilkan kinerja terbaik. Pada Top-10, model ini memperoleh precision sebesar 0,364, recall sebesar 0,291, dan F1-score sebesar 0,323. Hasil ini lebih tinggi dibandingkan user-based CF dan popularity-based recommendation. Pada Top-5, precision lebih tinggi, yaitu 0,417, tetapi recall lebih rendah, yaitu 0,238. Kondisi ini wajar karena daftar rekomendasi yang lebih pendek cenderung lebih selektif, sehingga proporsi item relevan lebih tinggi. Namun, jumlah item relevan yang berhasil ditemukan menjadi lebih sedikit. Pada Top-15, recall meningkat menjadi 0,326, tetapi precision menurun menjadi 0,331. Hal ini menunjukkan bahwa semakin banyak item yang direkomendasikan, semakin besar peluang sistem menemukan item relevan, tetapi risiko memasukkan item kurang relevan juga meningkat.

### Perbandingan kinerja Top-10

Evaluasi precision, recall, dan F1-score pada rekomendasi Top-10.



Grafik tersebut memperjelas bahwa item-based collaborative filtering dengan cosine similarity memiliki nilai precision, recall, dan F1-score paling tinggi pada rekomendasi Top-10. Model popularity-based menghasilkan kinerja paling rendah karena hanya merekomendasikan item populer tanpa mempertimbangkan kedekatan preferensi pengguna. Model user-based cosine menghasilkan kinerja lebih baik dari baseline, tetapi masih berada di bawah item-based cosine. Hasil ini menunjukkan bahwa cosine similarity bekerja lebih optimal ketika digunakan untuk menghitung kemiripan antar item pada dataset yang memiliki tingkat sparsity tinggi.

Untuk melihat hasil rekomendasi secara lebih konkret, penelitian ini mengambil satu contoh pengguna anonim, yaitu User-087. Pengguna ini memiliki riwayat interaksi dengan beberapa materi seperti “Pengantar Data Mining”, “Dasar Machine Learning”, “Evaluasi Model Klasifikasi”, dan “Python untuk Analisis Data”. Berdasarkan pola tersebut, sistem menghasilkan rekomendasi Top-5 seperti pada Tabel 4.

**Tabel 4. Contoh Hasil Rekomendasi untuk User-087**

| Peringkat | Item yang Direkomendasikan                          | Skor Prediksi | Status Relevansi |
|-----------|-----------------------------------------------------|---------------|------------------|
| 1         | Sistem Rekomendasi Berbasis Collaborative Filtering | 4,71          | Relevan          |
| 2         | Cosine Similarity untuk Analisis Kemiripan Data     | 4,63          | Relevan          |
| 3         | Evaluasi Sistem Rekomendasi dengan MAE dan RMSE     | 4,52          | Relevan          |
| 4         | Natural Language Processing Dasar                   | 4,11          | Tidak relevan    |
| 5         | Visualisasi Data dengan Python                      | 4,06          | Relevan          |

Dari lima item yang direkomendasikan kepada User-087, empat item dinilai relevan berdasarkan data uji. Satu item tidak relevan, yaitu “Natural Language Processing Dasar”. Hasil ini menunjukkan bahwa sistem mampu membaca pola minat pengguna secara cukup baik. Pengguna yang sebelumnya mengakses materi data mining dan machine learning cenderung menerima rekomendasi lanjutan yang berhubungan dengan sistem rekomendasi, cosine similarity, dan evaluasi model. Namun, sistem juga masih dapat menghasilkan rekomendasi yang kurang tepat. Hal ini dapat terjadi karena beberapa pengguna lain yang memiliki pola interaksi mirip dengan User-087 juga mengakses materi Natural Language Processing. Dengan kata lain, sistem membaca kemiripan kolektif, tetapi belum memahami sepenuhnya tujuan belajar individu.

## Pembahasan

Hasil penelitian menunjukkan bahwa collaborative filtering berbasis cosine similarity dapat digunakan untuk menghasilkan rekomendasi pembelajaran digital secara terukur. Nilai MAE sebesar 0,612 dan RMSE sebesar 0,824 pada item-based cosine menunjukkan bahwa model memiliki kesalahan prediksi yang lebih rendah dibandingkan baseline. Temuan ini mendukung pandangan bahwa collaborative filtering efektif digunakan untuk mengolah data interaksi pengguna dalam sistem rekomendasi (Romadhon et al., 2020). Hasil ini juga konsisten dengan penelitian Jena et al. (2023), yang menunjukkan bahwa model collaborative filtering dapat mendukung rekomendasi kursus e-learning secara personal. Dalam konteks pembelajaran digital, hasil tersebut memperlihatkan bahwa data interaksi sederhana dapat diolah menjadi rekomendasi yang bermakna jika sistem memiliki mekanisme similarity yang tepat.

Keunggulan item-based collaborative filtering dalam penelitian ini dapat dijelaskan melalui stabilitas hubungan antar item. Item pembelajaran biasanya memiliki keterkaitan topik yang lebih konsisten dibandingkan preferensi pengguna. Materi “Cosine Similarity” lebih dekat dengan “Collaborative Filtering” dibandingkan dengan “Manajemen Keuangan”, terlepas dari siapa pengguna yang mengaksesnya. Pola ini membuat perhitungan kemiripan antar item lebih stabil. Temuan ini sejalan dengan penelitian Pan et al. (2021), yang menggunakan collaborative filtering untuk mendukung rekomendasi kursus daring. Li dan Ye (2020) juga menunjukkan bahwa rekomendasi kursus dalam pendidikan online dapat dibangun dari pola hubungan antara pengguna dan kursus. Dengan demikian, pendekatan item-based dapat menjadi pilihan yang kuat untuk platform pembelajaran digital yang memiliki item pembelajaran dengan relasi topik yang jelas.

Hasil penelitian juga mendukung penggunaan cosine similarity sebagai metode pengukuran kemiripan. Cosine similarity mampu menghitung kedekatan pola interaksi antar item meskipun jumlah interaksi tidak sama. Dalam penelitian ini, cosine similarity mengungguli Pearson correlation dan Euclidean distance pada skenario item-based. Hal ini sejalan dengan Mana dan Sasipraba (2021), yang menempatkan cosine similarity sebagai salah satu metode penting dalam model rekomendasi berbasis similarity. Hasil ini juga sejalan dengan Yuniardini dan Widiyaningtyas (2024), yang menunjukkan bahwa cosine similarity dapat menjadi pembanding kuat terhadap Pearson correlation dalam collaborative filtering. Selain itu, Ma'ruf dan Qoiriah (2022) menunjukkan bahwa cosine similarity dapat digunakan secara efektif dalam item-based collaborative filtering, meskipun domain penelitian mereka adalah rekomendasi film.

Namun, hasil penelitian juga menunjukkan bahwa cosine similarity belum sepenuhnya menyelesaikan masalah sparsity. Dataset penelitian memiliki sparsity sebesar 95,12 persen. Angka ini menunjukkan bahwa sebagian besar kombinasi pengguna dan item tidak memiliki nilai interaksi. Pada kondisi seperti ini, sistem hanya dapat menghitung similarity berdasarkan data yang tersedia. Jika dua item jarang diakses oleh pengguna yang sama, nilai kemiripan keduanya menjadi sulit dipastikan. Hal ini sesuai dengan Huynh et al. (2020), yang menyatakan bahwa sparsity menjadi tantangan penting dalam collaborative filtering dan dapat diatasi melalui integrasi konteks. Tolety dan Prasad (2022) juga menekankan perlunya pendekatan hybrid untuk memperkuat rekomendasi ketika data interaksi tidak cukup padat.

Dibandingkan dengan penelitian yang menggunakan pendekatan hybrid, hasil penelitian ini menunjukkan bahwa cosine similarity tetap dapat menjadi model awal yang layak. Tolety dan Prasad (2022) menggabungkan content-based filtering dan collaborative filtering untuk meningkatkan rekomendasi e-learning. Chang et al. (2016) mengintegrasikan collaborative filtering dengan artificial immune systems. Guo et al. (2024) menambahkan dynamic time weighting dan trust value untuk menangani perubahan preferensi pengguna. Al Sabri (2021) menggunakan genetic algorithm untuk memperbaiki pengukuran similarity. Penelitian ini berbeda karena tidak menambahkan algoritma kompleks, melainkan menguji kinerja cosine similarity secara spesifik. Hasilnya menunjukkan bahwa metode sederhana masih mampu menghasilkan rekomendasi yang cukup baik, terutama ketika digunakan pada skema item-based.

Meskipun demikian, model ini masih memiliki keterbatasan. Pertama, sistem belum memperhitungkan perubahan minat pengguna berdasarkan waktu. Dalam pembelajaran digital, pengguna dapat berubah minat setelah menyelesaikan topik tertentu. Misalnya, pengguna yang awalnya mempelajari dasar Python dapat berpindah ke data mining, machine learning, atau visualisasi data. Jika sistem hanya menggunakan data historis tanpa bobot waktu, rekomendasi dapat tertinggal dari kebutuhan terbaru pengguna. Hal ini sesuai dengan Guo et al. (2024), yang menekankan pentingnya dynamic time weighting dalam rekomendasi sumber belajar online. Kedua, sistem belum memanfaatkan informasi konten seperti deskripsi kursus, kategori materi, tingkat kesulitan, atau prasyarat pembelajaran. Padahal, informasi konten dapat membantu memperbaiki rekomendasi untuk item baru yang belum memiliki banyak interaksi.

Ketiga, sistem masih berisiko merekomendasikan item populer secara berlebihan. Item yang sering diakses oleh banyak pengguna memiliki peluang lebih besar untuk muncul dalam daftar rekomendasi. Kondisi ini dapat mengurangi keragaman rekomendasi dan membuat item yang kurang populer sulit ditemukan. Dalam konteks pembelajaran, masalah ini penting karena item yang kurang populer belum tentu kurang relevan. Beberapa materi lanjutan atau materi khusus mungkin hanya dibutuhkan oleh segmen pengguna tertentu. Oleh karena itu, evaluasi sistem rekomendasi tidak cukup hanya melihat precision dan recall, tetapi juga perlu mempertimbangkan diversity, novelty, dan coverage pada penelitian lanjutan. Li (2022) menekankan bahwa sistem rekomendasi media digital perlu mempertimbangkan klasifikasi semantik agar rekomendasi tidak hanya bergantung pada popularitas atau pola interaksi umum.

Temuan penelitian ini juga memiliki implikasi praktis bagi pengembang platform pembelajaran digital. Pertama, platform dapat menggunakan item-based collaborative filtering berbasis cosine similarity sebagai

model rekomendasi awal karena metode ini sederhana, ringan, dan mudah diimplementasikan. Model ini cocok untuk institusi yang belum memiliki infrastruktur machine learning kompleks. Kedua, platform perlu memastikan bahwa data interaksi pengguna terekam dengan baik. Data klik, rating, durasi akses, penyelesaian materi, dan riwayat pemilihan kursus dapat menjadi sumber penting untuk membangun rekomendasi. Ketiga, pengelola platform perlu menyediakan mekanisme umpan balik agar pengguna dapat menilai relevansi rekomendasi. Umpan balik tersebut akan memperkaya matriks user-item dan meningkatkan kualitas rekomendasi dari waktu ke waktu.

Implikasi teoretis penelitian ini terletak pada penguatan posisi cosine similarity dalam sistem rekomendasi pembelajaran digital. Hasil penelitian menunjukkan bahwa cosine similarity masih relevan sebagai metode dasar dalam collaborative filtering. Temuan ini mendukung penelitian Rodríguez Marín et al. (2016), Zhong dan Ding (2022), serta Amin et al. (2023), yang menunjukkan bahwa sistem rekomendasi pembelajaran dapat dibangun dari pola interaksi pengguna dengan objek belajar. Hasil ini juga memperjelas bahwa pengukuran similarity tetap menjadi inti collaborative filtering. Tanpa pengukuran similarity yang tepat, sistem sulit menghasilkan rekomendasi yang relevan. Oleh karena itu, penelitian ini memberi kontribusi dengan menunjukkan bahwa cosine similarity dapat menjadi metode dasar yang efektif, meskipun tetap membutuhkan pengembangan lanjutan untuk menghadapi data jarang dan perubahan preferensi.

Hasil penelitian juga dapat dibandingkan dengan konteks rekomendasi pendidikan di Indonesia. Fernando et al. (2022) menggunakan collaborative filtering dan k-means clustering pada sistem rekomendasi mata kuliah. Elnursa et al. (2023) mengembangkan sistem rekomendasi pemilihan program MSIB bagi mahasiswa pendidikan informatika. Kedua penelitian tersebut menunjukkan bahwa sistem rekomendasi dapat membantu pengguna mengambil keputusan akademik. Penelitian ini memperluas arah tersebut dengan menekankan evaluasi kinerja cosine similarity secara kuantitatif pada platform pembelajaran digital. Dengan demikian, hasil penelitian tidak hanya relevan untuk pengembangan sistem, tetapi juga untuk perencanaan layanan akademik berbasis data.

Secara keseluruhan, hasil penelitian menunjukkan bahwa item-based collaborative filtering menggunakan cosine similarity memberikan kinerja terbaik pada dataset simulatif yang digunakan. Model ini menghasilkan kesalahan prediksi lebih rendah dan relevansi rekomendasi lebih tinggi dibandingkan baseline. Namun, kinerja tersebut masih dipengaruhi oleh sparsity, distribusi interaksi yang tidak merata, dan keterbatasan informasi konteks. Oleh karena itu, penelitian lanjutan dapat mengembangkan model hybrid dengan menggabungkan cosine similarity, informasi konten, bobot waktu, dan konteks pembelajaran. Pengembangan tersebut dapat meningkatkan akurasi, relevansi, dan keberagaman rekomendasi. Dengan hasil ini, collaborative filtering berbasis cosine similarity dapat dinilai sebagai pendekatan awal yang layak, sederhana, dan empiris untuk mendukung personalisasi pembelajaran pada platform digital.

## KESIMPULAN

Penelitian ini menunjukkan bahwa sistem rekomendasi berbasis collaborative filtering menggunakan metode cosine similarity dapat diterapkan secara efektif pada platform pembelajaran digital. Hasil pengujian memperlihatkan bahwa pendekatan item-based collaborative filtering memberikan kinerja lebih baik dibandingkan user-based collaborative filtering dan baseline berbasis popularitas. Model item-based dengan cosine similarity menghasilkan nilai kesalahan prediksi yang lebih rendah serta relevansi rekomendasi yang lebih tinggi. Hal ini menunjukkan bahwa pola kemiripan antar item pembelajaran lebih stabil dibandingkan pola kemiripan antar pengguna.

Secara umum, cosine similarity mampu membaca hubungan antar item berdasarkan pola interaksi pengguna. Sistem dapat merekomendasikan materi pembelajaran yang sesuai dengan riwayat akses, minat, dan kecenderungan belajar pengguna. Rekomendasi yang dihasilkan juga menunjukkan bahwa data interaksi

seederhana, seperti rating, klik, penyelesaian materi, dan frekuensi akses, dapat dimanfaatkan untuk membangun rekomendasi yang personal dan terukur.

Namun, penelitian ini juga menemukan bahwa metode cosine similarity masih memiliki keterbatasan. Tingkat sparsity yang tinggi menyebabkan sebagian hubungan user-item tidak dapat dianalisis secara optimal. Selain itu, metode ini belum sepenuhnya mampu menangani perubahan minat pengguna, cold start, dan kebutuhan pembelajaran yang bersifat dinamis. Oleh karena itu, meskipun cosine similarity layak digunakan sebagai model awal, pengembangannya tetap diperlukan.

Implikasi dari penelitian ini menunjukkan bahwa platform pembelajaran digital dapat menggunakan item-based collaborative filtering berbasis cosine similarity sebagai dasar sistem rekomendasi yang sederhana, ringan, dan mudah diterapkan. Model ini cocok digunakan pada institusi pendidikan yang mulai mengembangkan layanan pembelajaran berbasis data. Untuk penelitian selanjutnya, sistem rekomendasi dapat ditingkatkan dengan menambahkan informasi konten, bobot waktu, konteks pembelajaran, serta evaluasi metrik tambahan seperti diversity, novelty, dan coverage. Dengan demikian, sistem rekomendasi dapat menghasilkan saran pembelajaran yang lebih akurat, relevan, dan adaptif terhadap kebutuhan pengguna.

## DAFTAR PUSTAKA

- Al Sabri, M. A. M. A. (2021). Hybrid measuring the similarity value based on genetic algorithm for improving prediction in a collaborative filtering recommendation system: Recommendation system. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 10(2), 165–182. <https://doi.org/10.14201/ADCAIJ2021102165182>
- Amin, S., Uddin, M. I., Mashwani, W. K., Alarood, A. A., Alzahrani, A., & Alzahrani, A. O. (2023). Developing a personalized e-learning and MOOC recommender system in IoT-enabled smart education. *IEEE Access*, 11, 136437–136455. <https://doi.org/10.1109/ACCESS.2023.3336676>
- Chang, P.-C., Lin, C.-H., & Chen, M.-H. (2016). A hybrid course recommendation system by integrating collaborative filtering and artificial immune systems. *Algorithms*, 9(3), Article 47. <https://doi.org/10.3390/a9030047>
- Elnursa, D. B., Nofriana, V., Syamsuri, A., & Cahyani, L. (2023). Sistem rekomendasi pemilihan program MSIB bagi mahasiswa pendidikan informatika. *SHIFT: Journal of Information Technology*, 3(2), 34–45. <https://doi.org/10.24252/shift.v3i2.92>
- Fernando, E., Mudjiraharjo, P., & Aswin, M. (2022). Implementasi pendekatan collaborative filtering dan k-means clustering pada sistem rekomendasi mata kuliah. *JIKO: Jurnal Informatika dan Komputer*, 5(2), 84–91. <https://doi.org/10.33387/jiko.v5i2.4559>
- Guo, P., Nasir, M. K. M., & Xu, Y. (2024). Collaborative filtering recommender system for online learning resources with integrated dynamic time weighting and trust value calculation. *TEM Journal*, 13(2), 1352–1361. <https://doi.org/10.18421/TEM132-49>
- Huynh, H. X., Phan, N. Q., Pham, N. M., Pham, T. H., Huynh, T. T., Nguyen, T. H., & Do, T. N. (2020). Context-similarity collaborative filtering recommendation. *IEEE Access*, 8, 33342–33351. <https://doi.org/10.1109/ACCESS.2020.2973755>
- Jena, K. K., Bhoi, S. K., Malik, T. K., Sahoo, K. S., Jhanjhi, N. Z., Bhatia, S., & Amsaad, F. (2023). E-learning course recommender system using collaborative filtering models. *Electronics*, 12(1), Article 157. <https://doi.org/10.3390/electronics12010157>

- Li, J., & Ye, Z. (2020). Course recommendations in online education based on collaborative filtering recommendation algorithm. *Complexity*, 2020, Article 6619249. <https://doi.org/10.1155/2020/6619249>
- Li, X. (2022). Research and implementation of digital media recommendation system based on semantic classification. *Advances in Multimedia*, 2022, Article 4070827. <https://doi.org/10.1155/2022/4070827>
- Mana, S. C., & Sasipraba, T. (2021). Research on cosine similarity and Pearson correlation based recommendation models. *Journal of Physics: Conference Series*, 1770(1), Article 012014. <https://doi.org/10.1088/1742-6596/1770/1/012014>
- Ma'ruf, M. A., & Qoiriah, A. (2022). Perbandingan algoritma cosine similarity dan euclidean distance pada sistem rekomendasi film dengan metode item-based collaborative filtering. *Journal of Informatics and Computer Science*, 4(2), 160–168. <https://doi.org/10.26740/jinacs.v4n02.p160-168>
- Pan, Z., Zhao, L., Zhong, X., & Xia, Z. (2021). Application of collaborative filtering recommendation algorithm in internet online courses. In *Proceedings of the 6th International Conference on Big Data and Computing* (pp. 142–147). Association for Computing Machinery. <https://doi.org/10.1145/3469968.3469992>
- Rodríguez Marín, P. A., Pérez Zapata, Á. M., Londoño Rojas, L. F., & Duque Mendez, N. D. (2016). Sistema de recomendación de objetos de aprendizaje a través de filtrado colaborativo. *Teknos Revista Científica*, 16(2), 85–94. <https://doi.org/10.25044/25392190.824>
- Romadhon, Z., Sediyo, E., & Widodo, C. E. (2020). Various implementation of collaborative filtering-based approach on recommendation systems using similarity. *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, 5(3), 179–186. <https://doi.org/10.22219/KINETIK.V5I3.1062>
- Tolety, V. B. P., & Prasad, E. V. (2022). Hybrid content and collaborative filtering based recommendation system for e-learning platforms. *Bulletin of Electrical Engineering and Informatics*, 11(3), 1543–1549. <https://doi.org/10.11591/eei.v11i3.3861>
- Yuniardini, F., & Widiyaningtyas, T. (2024). Analisis perbandingan Pearson correlation dan cosine similarity pada rekomendasi musik berbasis collaborative filtering. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 555–564. <https://doi.org/10.29408/edumatic.v8i2.27781>
- Zhong, M., & Ding, R. (2022). Design of a personalized recommendation system for learning resources based on collaborative filtering. *International Journal of Circuits, Systems and Signal Processing*, 16, 122–131. <https://doi.org/10.46300/9106.2022.16.16>