

Optimizing Alternating Least Squares for Recommender Systems Using Particle Swarm Optimization

Fiddin Yusufda A'la^{*1}, Nurul Firdaus², Andy Supriyadi³

^{1,2,3}Applied Data Science and AI Research Group, Universitas Sebelas Maret, Indonesia

Email: ¹fiddin@staff.uns.ac.id

Received: Jul 21, 2025; Revised: Agu 14, 2025; Accepted: Agu 14, 2025; Published: Sep 14, 2025

Abstract

Recommender systems play a crucial role in various digital platforms by assisting users in discovering relevant items. The research problem addressed in this study is the limited predictive accuracy of ALS-based recommender systems due to suboptimal parameter selection. This study explores how Particle Swarm Optimization (PSO) can be leveraged for parameter optimization to address this limitation. The dataset used is MovieLens 1M, which contains over one million user ratings for thousands of movies. The research process includes data preprocessing, data splitting, model training, and evaluation using Root Mean Squared Error (RMSE) and Mean Absolute Error (MAE) as the primary metrics. The evaluation results indicate a significant improvement in model performance after optimization, with RMSE decreasing from 0.895 to 0.860 and MAE from 0.704 to 0.680. These findings demonstrate that optimization algorithms can effectively improve the prediction accuracy of recommendation systems. This research contributes to the application of swarm-based optimization techniques in enhancing matrix factorization-based recommender systems.

Keywords: ALS, MAE, MovieLens, PSO, recommender system, RMSE.

This work is an open access article and licensed under a Creative Commons Attribution-Non Commercial 4.0 International License



1. PENDAHULUAN

Peningkatan penggunaan sistem rekomendasi dalam berbagai platform digital, seperti *e-commerce* [1], [2], [3], [4] layanan *streaming* [5], [6], [7], [8] dan media sosial [9], [10], [11], [12] mengalami peningkatan yang signifikan. Sistem rekomendasi berperan penting dalam menyaring dan menyajikan informasi yang relevan kepada pengguna di tengah derasnya arus data, dengan tujuan meningkatkan pengalaman pengguna. Salah satu pendekatan yang umum digunakan dalam sistem rekomendasi adalah *Collaborative Filtering*, yang mengandalkan pola interaksi historis antara pengguna dan item untuk memprediksi preferensi di masa mendatang.

Di antara berbagai algoritma *Collaborative Filtering*, *Alternating Least Squares* (ALS) menjadi metode populer karena kemampuannya dalam menangani data skala besar dan sifat data yang *sparse* [1], [13], [14], [15]. ALS bekerja dengan memfaktorkan matriks interaksi *user-item* ke dalam representasi vektor laten yang dioptimalkan secara iteratif. Namun, performa ALS sangat dipengaruhi oleh pemilihan parameter *hyperparameter* seperti jumlah dimensi laten (*latent factors*), tingkat regularisasi, dan jumlah iterasi. Pemilihan parameter yang tidak tepat dapat menurunkan akurasi prediksi dan efisiensi model.


Untuk mengatasi tantangan ini, pendekatan optimasi metaheuristik seperti *Particle Swarm Optimization* (PSO) mulai banyak dieksplorasi. PSO berhasil meningkatkan kinerja *machine learning* dalam analisis data COVID-19 [16], peningkatan kinerja CNN dengan PSO [17] untuk klasifikasi photomask [18], optimasi model *deep learning* menggunakan PSO untuk prediksi data PM2.5 Beijing [19], peningkatan pembelajaran personal berbasis *decision support system* dengan PSO [20]. Banyak

penerapan lain tentang optimasi berbasis PSO [21]. PSO juga dimanfaatkan untuk meningkatkan kinerja dari *Deep convolutional neural networks (DCNNs)* [22], *Adaptive Two-Population Strategy* [23], *Self-Organizing Mapping for Nash Equilibrium Strategy* [24], pembobotan secara adaptif dengan multi input dan multi output *fuzzy logic* [25], *dual population adaptive mutation* [26]. PSO, yang terinspirasi dari perilaku sosial kawanan burung, mampu melakukan pencarian solusi optimal dalam ruang parameter yang luas secara efisien dan adaptif. Integrasi PSO dalam proses tuning *hyperparameter* ALS diharapkan dapat meningkatkan performa sistem rekomendasi, baik dari segi akurasi maupun kecepatan konvergensi.

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi pendekatan *hybrid* dengan menggabungkan ALS sebagai model dasar dan PSO sebagai metode optimasi *hyperparameter*. Melalui eksperimen yang dilakukan pada dataset rekomendasi, penelitian ini berupaya menunjukkan bahwa optimasi berbasis PSO mampu memberikan hasil yang lebih unggul dibandingkan tuning manual atau teknik *grid search* konvensional. Dengan demikian, kontribusi utama dari studi ini adalah menawarkan strategi peningkatan kinerja sistem rekomendasi yang lebih efektif dan adaptif.

2. METODE PENELITIAN

Gambar 1 menunjukkan alur eksperimen yang dilakukan. Langkah pertama dimulai dengan merumuskan tujuan analisis, yaitu membangun model prediksi atau sistem rekomendasi yang didasarkan pada algoritma ALS dan PSO. Pada tahap ini juga dilakukan penyiapan lingkungan eksperimen, di mana penelitian memanfaatkan *Google Colab* sebagai platform utama dan menggunakan *Python* sebagai bahasa pemrogramannya.



Gambar 1. Diagram alir eksperimen

Dataset yang digunakan berasal dari sumber publik MovieLens 1M dan diimpor dalam format .dat. Langkah ini bertujuan untuk memastikan bahwa data tersedia dalam format yang tepat untuk keperluan analisis. Pada tahap ini juga dilakukan eksplorasi awal guna memahami dimensi dataset serta jenis fitur yang terdapat di dalamnya.

Tahap pra-pemrosesan dilakukan untuk memastikan data bersih dan siap digunakan dalam proses pemodelan [27], [28]. Beberapa langkah penting diterapkan pada tahap ini. Langkah pertama adalah memeriksa keberadaan data duplikat, yaitu baris-baris yang memiliki nilai identik sepenuhnya. Data duplikat harus dihapus karena dapat memengaruhi distribusi data, menimbulkan bias, dan menyebabkan model belajar dari pola yang tidak valid atau berulang. Langkah kedua adalah memeriksa data kosong atau nilai yang hilang (*null values*). Berdasarkan hasil pengecekan, tidak ditemukan adanya duplikasi maupun data kosong dalam dataset ini.

Setelah melalui proses pembersihan, data kemudian dibagi menjadi tiga subset, yaitu data latih, data validasi, dan data uji. Data latih (60%) digunakan untuk membangun model dan mengenali pola dari data. Data validasi (20%) berperan dalam mengevaluasi kinerja model selama proses pelatihan serta membantu dalam penyesuaian parameter untuk mencegah *overfitting*. Sementara itu, data uji (20%) dimanfaatkan di tahap akhir untuk mengukur performa model terhadap data yang belum pernah dilihat sebelumnya.

Tahap berikutnya merupakan inti dari proses pemodelan, di mana algoritma utama yang diterapkan adalah ALS, yang digunakan untuk memfaktorkan matriks interaksi antara pengguna dan item dalam sistem rekomendasi. PSO, algoritma optimasi untuk mencari parameter terbaik. Model yang telah melalui proses optimasi menggunakan set data validasi kemudian dievaluasi menggunakan data uji untuk menilai performanya secara objektif. Evaluasi ini umumnya dilakukan dengan menggunakan metrik seperti *Root Mean Squared Error (RMSE)* dan *Mean Absolute Error (MAE)*.

2.1. Dataset

Dataset ini memuat sebanyak 1.000.209 rating anonim terhadap kurang lebih 3.900 judul film, yang diberikan oleh 6.040 pengguna terdaftar di *platform* MovieLens pada tahun 2000 [29]. Setiap entri mencerminkan interaksi pengguna dengan film dalam bentuk skor penilaian dengan skala 1 hingga 5. Selain data rating, dataset ini juga mencakup informasi tambahan seperti jenis kelamin, usia, pekerjaan, dan lokasi pengguna (berdasarkan kode pos), serta metadata film seperti judul dan *genre*. Karena struktur dan keragamannya yang cukup lengkap, dataset ini secara luas dimanfaatkan sebagai tolok ukur (*benchmark*) dalam berbagai studi yang berfokus pada pengembangan dan evaluasi sistem rekomendasi berbasis *collaborative filtering*. Ilustrasi data setelah proses penggabungan antara tabel pengguna, film, dan rating ditampilkan pada Tabel 1.

Tabel 1. Contoh data MovieLens 1M

User ID	Movie ID	Rating	Timestamp	Gender	Age	Occupation	Zip-code	Title	Genres
6040	562	5	956704746	M	25	6	11106	Welcome to the Dollhouse (1995)	Comedy Drama
6040	1096	4	956715648	M	25	6	11106	Sophie's Choice (1982)	Drama
6040	1097	4	956715569	M	25	6	11106	E.T. the Extra-Terrestrial (1982)	Children's Drama Fantasy Sci-Fi
...	...	...	...	...	...	...	...	...	...

2.2. Alternating Least Squares (ALS)

Alternating Least Squares (ALS) adalah algoritma *matrix factorization* yang umum dipakai untuk sistem rekomendasi. ALS memfaktorkan matriks interaksi pengguna-item menjadi dua matriks faktor laten (user dan item), yang dikalibrasi bergantian untuk meminimalkan *squared error*. Kelebihannya adalah skalabilitas dan kemudahan paralelisasi, cocok untuk data besar [30] [31] [32].

Model *Singular Value Decomposition (SVD)* diterapkan menggunakan *library Surprise*, yang telah banyak digunakan dalam studi sistem rekomendasi. Dataset MovieLens 1M terlebih dahulu diubah ke format khusus Surprise dengan skala rating antara 1 hingga 5. Setelah itu, model dilatih menggunakan set data latih. Beberapa parameter penting dalam SVD di *Surprise* mencakup jumlah faktor laten (*n_factors*) yang diset ke 100, jumlah iterasi (*epochs*) sebanyak 20, serta aktivasi penggunaan bias. Selain itu, tersedia pengaturan awal faktor, tingkat pembelajaran global (*lr_all* = 0.005), dan parameter regularisasi umum (*reg_all* = 0.02). Surprise juga memungkinkan pengaturan granular terhadap *learning rate* dan regularisasi masing-masing komponen model, sehingga tuning dapat dilakukan secara lebih presisi untuk menangkap pola interaksi antara pengguna dan item, sekaligus meminimalkan risiko *overfitting*.

2.3. Particle Swarm Optimization (PSO)

Particle Swarm Optimization (PSO) adalah algoritma optimasi berbasis populasi [33]. Algoritma ini terinspirasi dari perilaku kolektif hewan seperti burung atau ikan dalam kawanan. Setiap solusi dalam PSO direpresentasikan sebagai partikel yang bergerak dalam ruang pencarian dan menyesuaikan posisinya berdasarkan pengalaman terbaiknya sendiri (*personal best*) serta pengalaman terbaik dari seluruh populasi (*global best*).

PSO dikenal karena kesederhanaannya, efisiensi komputasi, dan kemampuannya dalam mengeksplorasi ruang solusi secara efektif. Dalam penelitian ini, PSO digunakan untuk mengoptimalkan parameter model ALS. Parameter yang dimaksimalkan yaitu jumlah faktor laten dan tingkat regularisasi, guna meningkatkan akurasi sistem rekomendasi berbasis rating.

2.4. ALS + PSO

PSO berfungsi sebagai *meta-optimizer* yang membungkus proses pelatihan ALS. Dalam kerangka ini, setiap partikel PSO merepresentasikan satu set *hyperparameter* ALS, misalnya jumlah faktor laten, koefisien regularisasi, dan rasio pembelajaran. PSO menjelajahi ruang parameter secara *continue*. Gerakan kolektif kawanan partikel memfokuskan pencarian pada wilayah tertentu, sehingga cepat menemukan kombinasi parameter dengan kesalahan prediksi terendah misalnya RMSE atau MAE pada data validasi.

2.5. Evaluation

MAE adalah rata-rata dari nilai absolut selisih antara nilai sebenarnya (*actual*) dan nilai prediksi (*predicted*). Dalam sistem rekomendasi, MAE mengukur seberapa jauh prediksi rating dari nilai rating sebenarnya secara rata-rata, tanpa memperhitungkan arah *error* (positif atau negatif). Formula matematika untuk menghitung MAE ditunjukkan pada Persamaan 2.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

Di mana:

n = jumlah data (contoh: rating yang diuji)

y_i = nilai sebenarnya (TRUE rating)

$\hat{y}_i$ = nilai prediksi (PREDICTED rating)

RMSE adalah akar kuadrat dari rata-rata kuadrat selisih antara nilai sebenarnya dan nilai prediksi. RMSE memberi bobot lebih besar pada *error* yang besar karena kuadrat, sehingga lebih sensitif terhadap *outlier*. Persamaan matematika untuk menghitung nilai RMSE ditunjukkan pada Persamaan 3.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

Di mana:

n = jumlah data


y_i = nilai sebenarnya

$\hat{y}_i$ = nilai prediksi

3. HASIL DAN PEMBAHASAN


3.1. Hasil Analisis Deskriptif

Dataset ini terdiri dari total 1.000.209 rating dengan rentang nilai 1 hingga 5. Mayoritas pengguna memberikan rating tinggi, di mana rating 4 menjadi yang paling dominan dengan 348.971 kali, diikuti rating 3 sebanyak 261.197 kali, dan rating 5 sebanyak 226.310 kali. Sementara itu, rating rendah relatif jarang diberikan, dengan rating 2 sebanyak 107.557 kali dan rating 1 sebanyak 56.174 kali. Distribusi ini menunjukkan kecenderungan penonton untuk memberikan penilaian positif terhadap film yang mereka tonton. Diagram perbandingan jumlah rating ditunjukkan pada Gambar 2.



Gambar 2. Perbandingan RMSE antara ALS dan ALS+PSO


Distribusi jenis kelamin dalam dataset menunjukkan bahwa dari total 1.000.209 data, sebanyak 753.769 atau sekitar tiga perempat berasal dari pengguna berjenis kelamin laki-laki (M), sedangkan 246.440 atau sekitar seperempat berasal dari pengguna berjenis kelamin perempuan (F). Ketimpangan proporsi ini mengindikasikan bahwa partisipasi laki-laki dalam memberikan rating film jauh lebih tinggi dibandingkan perempuan, yang dapat memengaruhi representasi preferensi dalam sistem rekomendasi. Diagram perbandingan jumlah jenis kelamin ditunjukkan pada Gambar 3.



Gambar 3. Distribusi jenis kelamin

3.2. Hasil Eksperimen


Hasil evaluasi model berdasarkan metrik RMSE ditampilkan pada Gambar 4. Terlihat bahwa model ALS menghasilkan nilai RMSE sebesar 0.895, yang mencerminkan tingkat kesalahan kuadrat rata-rata dalam prediksi rating pengguna. Setelah dilakukan optimasi menggunakan algoritma *Particle Swarm Optimization* (PSO), performa model meningkat dengan penurunan nilai RMSE menjadi 0.860. Penurunan ini menunjukkan bahwa integrasi PSO mampu membantu proses tuning parameter ALS secara lebih efektif, sehingga menghasilkan prediksi yang lebih akurat dan stabil terhadap data uji. Dengan demikian, kombinasi ALS + PSO terbukti lebih unggul dibandingkan ALS murni dalam hal akurasi prediktif.



Gambar 4. Perbandingan RMSE antara ALS dan ALS+PSO

Gambar 5 menyajikan hasil perbandingan performa model berdasarkan metrik *Mean Absolute Error* (MAE). Model ALS menunjukkan nilai MAE sebesar 0.704, yang mengindikasikan rata-rata selisih absolut antara prediksi dan nilai sebenarnya. Setelah dilakukan optimasi menggunakan algoritma PSO, nilai MAE menurun menjadi 0.680. Penurunan ini mencerminkan peningkatan akurasi model dalam memprediksi rating pengguna, dengan kesalahan rata-rata yang lebih kecil. Hasil ini memperkuat

temuan sebelumnya bahwa integrasi PSO dapat meningkatkan kinerja algoritma ALS, tidak hanya pada metrik RMSE tetapi juga pada MAE.



Gambar 5. Perbandingan MAE antara ALS dan ALS+PSO

3.3. Analisis Hasil Eksperimen

Evaluasi performa model dilakukan dengan dua metrik utama, yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE), sebagaimana telah dijelaskan pada Bab Metode. RMSE digunakan untuk mengukur tingkat kesalahan prediksi dengan memberikan penalti lebih besar pada kesalahan yang ekstrem, sedangkan MAE mengukur deviasi absolut rata-rata antara nilai prediksi dan nilai rating aktual.

Tahap pertama adalah membangun model *Alternating Least Squares* (ALS) sebagai model dasar. Berdasarkan evaluasi, model ALS menghasilkan nilai RMSE sebesar 0,895 dan MAE sebesar 0,704. Nilai RMSE ini menunjukkan bahwa rata-rata kesalahan kuadrat prediksi masih berada pada tingkat yang wajar untuk data sparse, sedangkan nilai MAE mengindikasikan bahwa perbedaan rata-rata secara absolut antara prediksi dan rating aktual berada di kisaran 0,7 poin. Hasil ini menandakan bahwa ALS mampu menangkap pola interaksi pengguna–item secara cukup baik, meskipun keterbatasan pada kompleksitas nonlinier dan parameter yang belum optimal masih terlihat.

Tahap berikutnya adalah melakukan optimasi parameter ALS menggunakan algoritma *Particle Swarm Optimization* (PSO) sebagaimana dirancang pada Bab Metode. Setelah integrasi PSO, model menunjukkan peningkatan performa dengan nilai RMSE turun menjadi 0,860 dan MAE menjadi 0,680. Penurunan ini membuktikan bahwa kombinasi parameter optimal yang ditemukan oleh PSO membantu ALS dalam mempelajari representasi matriks pengguna–item secara lebih akurat.

Secara keseluruhan, hasil ini mendukung hipotesis bahwa optimasi berbasis swarm mampu meningkatkan efektivitas model rekomendasi berbasis faktorisasi matriks. Penurunan nilai RMSE dan MAE menunjukkan peningkatan akurasi prediksi, sehingga pendekatan ALS + PSO layak dipertimbangkan untuk data dengan tingkat sparsitas tinggi seperti MovieLens.

4. DISKUSI

4.1. Interpretasi Hasil

Hasil evaluasi menunjukkan bahwa penerapan algoritma optimasi PSO pada model ALS mampu menghasilkan prediksi dengan tingkat kesalahan yang lebih rendah dibandingkan penggunaan ALS secara langsung. Temuan ini menegaskan pentingnya proses *tuning parameter* yang efektif dalam meningkatkan performa sistem rekomendasi berbasis *matrix factorization*. Dengan bantuan PSO, parameter-parameter ALS dapat disesuaikan secara lebih optimal, sehingga model lebih mampu menangkap pola tersembunyi dalam data interaksi pengguna dan item.

Penurunan nilai RMSE dan MAE setelah integrasi dengan PSO menunjukkan bahwa optimasi berbasis *swarm intelligence* dapat menjadi pendekatan yang andal dalam meningkatkan akurasi prediksi, terutama pada data yang bersifat *sparse*. Interpretasi ini memperkuat gagasan bahwa penggabungan teknik optimasi dengan model dasar yang kuat seperti ALS bukan hanya meningkatkan performa, tetapi juga memberikan stabilitas prediksi yang lebih baik. Oleh karena itu, strategi seperti ALS + PSO layak dipertimbangkan sebagai pendekatan yang unggul dalam pengembangan sistem rekomendasi yang efisien dan presisi. Penelitian ini memiliki urgensi yang tinggi dalam konteks pengembangan *data-driven applications* yang mengandalkan sistem rekomendasi, seperti *e-commerce*, layanan *streaming*, dan *platform* media sosial. Pada ranah informatika dan ilmu komputer, kontribusi utama penelitian ini terletak pada eksplorasi metode optimasi dalam *machine learning* dan peningkatan akurasi pada data *sparse* yang umum dihadapi dalam *collaborative filtering*.

Contoh konteks permasalahan ditunjukkan pada Tabel 2.

Tabel 2. Contoh dataset

	Film A	Film B	Film C
User1	5	?	3
User2	4	2	?
User3	?	5	?

? merupakan nilai rating yang akan diprediksi. ALS memfaktorkan matriks rating menjadi dua matriks:

P = matrix user (*user-feature*) → misal bentuk 3x2

Q = matrix item (*item-feature*) → misal bentuk 3x2

$$P = \begin{bmatrix} 0.9 & 0.1 \\ 0.8 & 0.2 \\ 0.2 & 0.7 \end{bmatrix}$$

$$Q = \begin{bmatrix} 1.0 & 0.3 \\ 0.4 & 0.9 \\ 0.6 & 0.8 \end{bmatrix}$$

$$\text{Prediksi} = \text{dot}(P[0], Q[1]) = (0.9 \times 0.4) + (0.1 \times 0.9) = 0.36 + 0.09 = \mathbf{0.45}$$

Tujuan PSO di sini adalah mencari parameter terbaik untuk ALS, misalnya:

n_factors (jumlah fitur)

reg_param (regularisasi)

alpha (untuk *implicit feedback*)

Misalnya, PSO menginisialisasi 3 partikel:

Partikel 1: [n_factors=20, reg=0.1]

Partikel 2: [n_factors=50, reg=0.05]

Partikel 3: [n_factors=30, reg=0.15]

Misal hasil evaluasi:

Partikel 1 → RMSE = 0.92

Partikel 2 → RMSE = 0.87

Partikel 3 → RMSE = 0.91

PSO akan mengarahkan semua partikel menuju konfigurasi Partikel 2 karena memiliki RMSE terendah.

4.2. Keterbatasan Penelitian

Meskipun penelitian ini berhasil menunjukkan peningkatan performa model rekomendasi melalui optimasi parameter menggunakan algoritma PSO, terdapat beberapa keterbatasan yang perlu diperhatikan. Pertama, penelitian ini hanya menggunakan satu dataset benchmark, yaitu MovieLens 1M, yang memiliki karakteristik khusus seperti struktur data yang relatif bersih dan skala rating tetap. Hal ini membatasi generalisasi hasil ke dataset lain yang lebih kompleks, lebih besar, atau dengan struktur data yang lebih heterogen. Kedua, eksperimen hanya difokuskan pada model ALS dan variasinya dengan optimasi PSO. Pendekatan ini belum membandingkan performa dengan model *deep learning* atau algoritma *hybrid* lain yang mungkin memiliki performa lebih tinggi.

5. KESIMPULAN

Penelitian ini bertujuan untuk membangun dan mengevaluasi sistem rekomendasi berbasis algoritma *Alternating Least Squares* (ALS) serta menguji pengaruh optimasi parameter menggunakan algoritma Particle Swarm Optimization (PSO). Berdasarkan hasil eksperimen dan evaluasi menggunakan metrik RMSE dan MAE, dapat disimpulkan bahwa integrasi PSO secara signifikan meningkatkan performa model ALS. Hal ini ditunjukkan oleh penurunan nilai RMSE dari 0.895 menjadi 0.860 dan MAE dari 0.704 menjadi 0.680, yang mencerminkan peningkatan akurasi dalam prediksi rating pengguna. ALS terbukti efektif dalam memodelkan interaksi laten antara pengguna dan item, namun masih rentan terhadap pemilihan parameter yang tidak optimal. Dengan menerapkan PSO, model mampu mengeksplorasi ruang parameter secara lebih efisien dan menghasilkan konfigurasi yang memberikan hasil terbaik. Temuan ini memperkuat pentingnya pendekatan optimasi dalam pengembangan sistem rekomendasi yang andal dan presisi. Secara keseluruhan, pendekatan ALS + PSO merupakan strategi yang menjanjikan untuk meningkatkan kualitas rekomendasi, terutama pada data dengan tingkat sparsity tinggi. Penelitian ini diharapkan dapat menjadi referensi bagi pengembangan sistem rekomendasi berbasis *matrix factorization* yang lebih adaptif dan optimal. Penelitian lanjutan dapat mencakup penerapan metode optimasi lain seperti *Genetic Algorithm* atau *Bayesian Optimization*, serta integrasi *context-aware features* untuk menghasilkan rekomendasi yang lebih personal dan relevan.

UCAPAN TERIMA KASIH

Karya ini didukung oleh Grup Riset **Applied Data Science and AI** di bawah skema Hibah Penelitian Grup Riset **Universitas Sebelas Maret** dengan Nomor Kontrak Penelitian: **371/UN27.22/PT.01.03/2025**.

DAFTAR PUSTAKA

- [1] S. Gosh, N. Nahar, M. A. Wahab, M. Biswas, M. S. Hossain, and K. Andersson, "Recommendation System for E-commerce Using Alternating Least Squares (ALS) on Apache Spark," Springer, 2021, pp. 880–893. doi: 10.1007/978-3-030-68154-8_75.
- [2] W.-E. Kong, T.-E. Tai, P. Naveen, and H. A. Santoso, "Performance Evaluation on E-Commerce Recommender System based on KNN, SVD, CoClustering and Ensemble

- Approaches,” *Journal of Informatics and Web Engineering*, vol. 3, no. 3, pp. 63–76, Oct. 2024, doi: 10.33093/jiwe.2024.3.3.4.
- [3] F. T. Abdul Hussien, A. M. S. Rahma, and H. B. Abdul Wahab, “Recommendation Systems For E-commerce Systems An Overview,” *J Phys Conf Ser*, vol. 1897, no. 1, p. 012024, May 2021, doi: 10.1088/1742-6596/1897/1/012024.
- [4] M. O. Puspitaningtyas, K. Puspita, Y. Alkhalifi, and Y. A. Wardani, “Implementation of Support Vector Machine, Particle Swarm Optimization, And Naïve Bayes Algorithms in Sentiment Analysis of Product Reviews: A Case Study of e-Commerce Lazada,” *Jurnal Riset Informatika*, vol. 7, no. 2, pp. 30–37, Mar. 2025, doi: 10.34288/jri.v7i2.362.
- [5] M. Bourreau and G. Gaudin, “Streaming platform and strategic recommendation bias,” *J Econ Manag Strategy*, vol. 31, no. 1, pp. 25–47, Feb. 2022, doi: 10.1111/jems.12452.
- [6] N. J. Nahar, L. K. Vishwamitra, and D. Sukheja, “Collaborative Learning based Recommendation System for Content Streaming Platform using Non-Negative Matrix Factorization Clustering,” *Procedia Comput Sci*, vol. 230, pp. 427–435, 2023, doi: 10.1016/j.procs.2023.12.098.
- [7] J. M. Azri Saputra, L. M. Huizen, and D. B. Arianto, “Sistem Rekomendasi Film pada Platform Streaming Menggunakan Metode Content-Based Filtering,” *Jurnal Transformatika*, vol. 22, no. 1, pp. 10–21, Jul. 2024, doi: 10.26623/transformatika.v22i1.7041.
- [8] Y. Shin, H.-S. Choi, Y. Nam, H. Cho, and E. Lee, “Particle Swarm Optimization Video Streaming Service in Vehicular Ad-Hoc Networks,” *IEEE Access*, vol. 10, pp. 102710–102723, 2022, doi: 10.1109/ACCESS.2022.3206786.
- [9] J. Xu, “Analysis of Social Media Algorithm Recommendation System,” *Studies in Social Science & Humanities*, vol. 1, no. 3, Oct. 2022, doi: 10.56397/SSSH.2022.10.06.
- [10] Y. A. Bekeneva and T. U. Eze, “Improved Social Network User Recommendation System—The Machine Learning Approach,” in *INTELS’22*, Basel Switzerland: MDPI, Jun. 2023, p. 13. doi: 10.3390/engproc2023033013.
- [11] A. Anandhan, M. A. Ismail, L. Shuib, W. S. N. Aiza, and M. M. Elaish, “Social Media Recommender Systems (SMRS): A Bibliometric Analysis Study 2000–2021,” *IEEE Access*, vol. 10, pp. 35479–35497, 2022, doi: 10.1109/ACCESS.2022.3161497.
- [12] M. Qi, J. Zhao, and Y. Feng, “An optimized public opinion communication system in social media networks based on K-means cluster analysis,” *Heliyon*, vol. 10, no. 24, p. e40033, Dec. 2024, doi: 10.1016/j.heliyon.2024.e40033.
- [13] G. Liu and X. Wu, “Using Collaborative Filtering Algorithms Combined with Doc2Vec for Movie Recommendation,” in *2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, IEEE, Mar. 2019, pp. 1461–1464. doi: 10.1109/ITNEC.2019.8729076.
- [14] K. V K and S. Murugesan, “An Effective Book Recommendation System using Weighted Alternating Least Square (WALS) Approach,” *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 4, 2024, doi: 10.14569/IJACSA.2024.0150463.
- [15] H. A. Adyatma and Z. K. A. Baizal, “Book Recommender System Using Matrix Factorization with Alternating Least Square Method,” *Journal of Information System Research (JOSH)*, vol. 4, no. 4, pp. 1286–1292, Jul. 2023, doi: 10.47065/josh.v4i4.3816.
- [16] H. S. Salem, M. A. Mead, and G. S. El-Taweel, “Particle Swarm Optimization-Based Hyperparameters Tuning of Machine Learning Models for Big COVID-19 Data Analysis,” *Journal of Computer and Communications*, vol. 12, no. 03, pp. 160–183, 2024, doi: 10.4236/jcc.2024.123010.
- [17] M. Munsarif, M. Sam’an, and A. Fahrezi, “Convolution neural network hyperparameter optimization using modified particle swarm optimization,” *Bulletin of Electrical Engineering and Informatics*, vol. 13, no. 2, pp. 1268–1275, Apr. 2024, doi: 10.11591/eei.v13i2.6112.
- [18] T.-Y. Hong and C.-C. Chen, “Hyperparameter optimization for convolutional neural network by opposite-based particle swarm optimization and an empirical study of photomask defect classification,” *Appl Soft Comput*, vol. 148, p. 110904, Nov. 2023, doi: 10.1016/j.asoc.2023.110904.

-
- [19] A. Pranolo, Y. Mao, A. P. Wibawa, A. B. P. Utama, and F. A. Dwiyanto, "Optimized Three Deep Learning Models Based-PSO Hyperparameters for Beijing PM2.5 Prediction," *Knowledge Engineering and Data Science*, vol. 5, no. 1, p. 53, Jun. 2022, doi: 10.17977/um018v5i12022p53-66.
- [20] R. Parkavi, P. Karthikeyan, and A. Sheik Abdullah, "Enhancing personalized learning with explainable AI: A chaotic particle swarm optimization based decision support system," *Appl Soft Comput*, vol. 156, p. 111451, May 2024, doi: 10.1016/j.asoc.2024.111451.
- [21] A. G. Gad, "Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review," *Archives of Computational Methods in Engineering*, vol. 29, no. 5, pp. 2531–2561, Aug. 2022, doi: 10.1007/s11831-021-09694-4.
- [22] G. Yuan, B. Wang, B. Xue, and M. Zhang, "Particle Swarm Optimization for Efficiently Evolving Deep Convolutional Neural Networks Using an Autoencoder-Based Encoding Strategy," *IEEE Transactions on Evolutionary Computation*, vol. 28, no. 5, pp. 1190–1204, Oct. 2024, doi: 10.1109/TEVC.2023.3245322.
- [23] M. Zhao, H. Zhao, and M. Zhao, "Particle Swarm Optimization Algorithm With Adaptive Two-Population Strategy," *IEEE Access*, vol. 11, pp. 62242–62260, 2023, doi: 10.1109/ACCESS.2023.3287859.
- [24] C. Zhao and D. Guo, "Particle Swarm Optimization Algorithm With Self-Organizing Mapping for Nash Equilibrium Strategy in Application of Multiobjective Optimization," *IEEE Trans Neural Netw Learn Syst*, vol. 32, no. 11, pp. 5179–5193, Nov. 2021, doi: 10.1109/TNNLS.2020.3027293.
- [25] X. Xia *et al.*, "A Particle Swarm Optimization With Adaptive Learning Weights Tuned by a Multiple-Input Multiple-Output Fuzzy Logic Controller," *IEEE Transactions on Fuzzy Systems*, vol. 31, no. 7, pp. 2464–2478, Jul. 2023, doi: 10.1109/TFUZZ.2022.3227464.
- [26] S. Ding, W. Li, and Y. Huang, "Particle swarm optimization algorithm with dual population adaptive mutation," in *2022 IEEE 21st International Conference on Cognitive Informatics & Cognitive Computing (ICCI*CC)*, IEEE, Dec. 2022, pp. 168–174. doi: 10.1109/ICCICC57084.2022.10101561.
- [27] S. S. Berutu, H. Budiati, J. Jatmika, and F. Gulo, "Data preprocessing approach for machine learning-based sentiment classification," *JURNAL INFOTEL*, vol. 15, no. 4, pp. 317–325, Nov. 2023, doi: 10.20895/infotel.v15i4.1030.
- [28] K. Maharana, S. Mondal, and B. Nemade, "A review: Data pre-processing and data augmentation techniques," *Global Transitions Proceedings*, vol. 3, no. 1, pp. 91–99, Jun. 2022, doi: 10.1016/j.gltp.2022.04.020.
- [29] F. M. Harper and J. A. Konstan, "The MovieLens Datasets," *ACM Trans Interact Intell Syst*, vol. 5, no. 4, pp. 1–19, Jan. 2016, doi: 10.1145/2827872.
- [30] H. A. Adyatma and Z. K. A. Baizal, "Book Recommender System Using Matrix Factorization with Alternating Least Square Method," *Journal of Information System Research (JOSH)*, vol. 4, no. 4, pp. 1286–1292, Jul. 2023, doi: 10.47065/josh.v4i4.3816.
- [31] N. P. Widyasprana, I. M. W. Wirawan, I. G. S. Astawa, and I. D. M. Bayu Atmaja Darmawan, "Analisis Algoritma ALS-MF (Alternating Least Square Matrix Factorization) dengan SVD (Singular Value Decomposition) pada Metode Collaborative Filtering," *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 13, no. 2, p. 347, Jul. 2024, doi: 10.24843/JLK.2024.v13.i02.p12.
- [32] Y. Zhou, D. Wilkinson, R. Schreiber, and R. Pan, "Large-Scale Parallel Collaborative Filtering for the Netflix Prize," in *Algorithmic Aspects in Information and Management*, Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 337–348. doi: 10.1007/978-3-540-68880-8_32.
- [33] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of ICNN'95 - International Conference on Neural Networks*, IEEE, pp. 1942–1948. doi: 10.1109/ICNN.1995.488968.
-