

Evaluasi Model Faktor Laten dalam Kondisi Kelangkaan Data: Studi Kasus Rendahnya Pembelian Ulang pada E-Commerce

Tria Rizky Rosmalia,
Universitas Negeri Surabaya, Indonesia
tria.22054@mbs.unesa.ac.id

Riska Dhenabayu,
Universitas Negeri Surabaya, Indonesia
riskadhenabayu@unesa.ac.id

Hujjatullah Fazlurrahman,
Universitas Negeri Surabaya, Indonesia
hujjatullahfazlurrahman@unesa.ac.id

Renny Sari Dewi,
Universitas Negeri Surabaya, Indonesia
rennydewi@unesa.ac.id

Abstract

The accuracy of recommendation systems is vital for successful personalization in e-commerce. However, the low frequency of repeat purchases creates high data sparsity, limiting models in capturing user preferences. This study compares two latent factor-based algorithms. Matrix Factorization (MF) and Neural Matrix Factorization (NeuMF), using the Olist transaction dataset through data preparation, k-core filtering, and leave last out splitting. Performance was evaluated using HR@10 and NDCG@10. Results show that MF outperforms NeuMF, achieving HR@10 of 0,057 and NDCG@10 of 0,133. Although NeuMF is more complex and represents a deeper learning-based approach, MF can still be more suitable in certain data conditions, especially when interactions are limited. These findings highlight that simpler models may remain more efficient under sparse data, while NeuMF requires richer interactions histories. The study emphasizes repeat purchase frequency as a key factor in designing adaptive recommendations systems.

Keywords: *Matrix Factorization, Neural Matrix Factorization, Product Recommendation, E-commerce, Machine Learning*

Abstrak

Akurasi sistem rekomendasi sangat penting untuk keberhasilan personalisasi pada platform e-commerce. Namun, rendahnya frekuensi pembelian ulang menimbulkan tingkat sparsity yang tinggi sehingga membatasi model dalam menangkap preferensi pengguna. Penelitian ini membandingkan dua algoritma berbasis latent factor, yaitu Matrix Factorization (MF) dan Neural Matrix Factorization (NeuMF), dalam menghasilkan rekomendasi produk pada kondisi interaksi pengguna yang terbatas. Metode eksperimen kuantitatif digunakan dengan dataset transaksi Olist melalui tahap persiapan data, k-core filtering dan skema pemisahan leave last out. Kinerja model dievaluasi menggunakan metrik HR@10 dan NDCG@10. Hasil menunjukkan bahwa MF memiliki kinerja lebih baik dibandingkan NeuMF, dengan HR@10 sebesar 0,057 dan NDCG@10 sebesar 0,133. Meskipun NeuMF lebih kompleks dan merupakan

pendekatan yang lebih baru, MF dapat lebih sesuai pada kondisi tertentu, khususnya saat interaksi sangat sedikit. Penelitian ini menegaskan bahwa frekuensi pembelian ulang merupakan faktor penting dalam merancang sistem yang lebih adaptif.

Keywords: *Matrix Factorization, Neural Matrix Factorization, Rekomendasi Produk, Personalisasi E-commerce, Konsumsi Berkelanjutan*

Pendahuluan

Perkembangan e-commerce tidak hanya mengubah cara konsumen berinteraksi dengan produk, tetapi juga menuntut perusahaan untuk memahami perilaku konsumen secara mendalam¹. Dalam persaingan digital yang semakin ketat, personalisasi produk menjadi strategi penting untuk meningkatkan pengalaman pelanggan dan mendorong performa bisnis². Penerapan sistem rekomendasi yang memanfaatkan *machine learning* menunjukkan dampak signifikan terhadap kinerja penjualan, ditandai dengan peningkatan pesanan lebih dari 30% pasca implementasi fitur personalisasi³.

Selain meningkatkan efektivitas penjualan, personalisasi juga berkontribusi pada efisiensi proses pencarian dan pemilihan produk. Rekomendasi yang semakin relevan membantu konsumen menemukan produk yang mereka butuhkan dengan lebih cepat, sehingga memperkuat kepercayaan dan kepuasan mereka⁴. Penelitian sebelumnya menunjukkan bahwa konten dan produk yang di personalisasi berpengaruh signifikan terhadap keputusan pembelian serta loyalitas pelanggan^{5 6}. Integrasi algoritma yang menganalisis perilaku pengguna, riwayat pembelian dan preferensi memungkinkan rekomendasi yang lebih akurat, sehingga membentuk ulang dinamika e-commerce dan memberikan keunggulan kompetitif berkelanjutan⁷.

Diantara berbagai metode yang ada Matrix Factorization (MF) dan Neural Matrix Factorization (NeuMF) menjadi algoritma unggulan karena kemampuannya menghasilkan prediksi yang akurat dan relevan^{8 9}. MF terbukti meningkatkan keterlibatan pengguna melalui

¹ Ni Kadek Santika Pradnyanita et al., "Analisis Pengaruh E-Commerce Terhadap Perubahan Pola Konsumsi Masyarakat: Tinjauan Literatur," *JUWARA: Jurnal Wawasan dan Aksara* 01, no. 01 (2025), <https://doi.org/10.25078/juwara.v1i1.4871>.

² Handi Dipo Santosa et al., "Analysis of the Impact of Online Marketing Campaigns on Consumer Behavior in Indonesia's E-Commerce Market," *Pinisi Discretion Review* 7, no. 2 (2024), <https://doi.org/10.26858/pdr.v7i2.66001>.

³ Nuraeni Johnson et al., "Enhancing E-Commerce with Big Data: From Browsing to Buying Through Recommendation Systems," *International Journal of Entrepreneurship, Business and Creative Economy* 4, no. 1 (2024): 130–45, <https://doi.org/10.31098/ijebce.v4i1.1930>.

⁴ Regita Patricia Agustina et al., "Kepercayaan Kepuasan Loyalitas Konsumen Dalam Membeli Barang Di Aplikasi Online Shop," *Jurnal Kajian dan Penalaran Ilmu Manajemen* 2, no. 1 (2024): 261–72, <https://doi.org/10.59031/jkpim.v2i1.351>.

⁵ Suryati Suryati et al., "The Effect of Customer Engagement, Content Personalization, and Trust on Purchasing Decisions in Indonesian E-Commerce: A Case Study on the Fashion Industry," *West Science Journal Economic and Entrepreneurship* 1, no. 06 (2023): 134–43, <https://doi.org/10.58812/wsjee.v1i06.453>.

⁶ Esti Tri Endarwati et al., "The Effect of Product Personalization, User Experience, and Consumer Trust on the Level of E-Commerce Consumer Satisfaction in Indonesia," *Jurnal Bisnisan : Riset Bisnis Dan Manajemen* 6, no. 1 (2024): 163–79, <https://doi.org/10.52005/bisnisan.v6i1.239>.

⁷ Vasyil Nesterov, "Analyzing User Behavior Patterns For Personalized Recommender Systems In E-Commerce: A Literature Review," *Automation of Technological and Business Processes* 16, no. 3 (2024): 69–76, <https://doi.org/10.15673/atbp.v16i3.2923>.

⁸ Chong Chen et al., "Efficient Neural Matrix Factorization without Sampling for Recommendation," *ACM Transactions on Information Systems* 38, no. 2 (2020): 1–28, <https://doi.org/10.1145/3373807>.

⁹ Janny Eka Prayogo et al., "Analisis Perbandingan Model Matrix Factorization dan K-Nearest Neighbor dalam Mesin Rekomendasi Collaborative Berbasis Prediksi Rating," *Jurnal Informatika Universitas Pamulang* 5, no. 4 (2021): 506, <https://doi.org/10.32493/informatika.v5i4.7379>.

rekomendasi yang lebih terarah¹⁰ serta mampu menangkap faktor-faktor laten yang mencerminkan preferensi pengguna, sehingga rekomendasi yang dihasilkan lebih relevan secara kontekstual¹¹.

Sedangkan NeuMF menggabungkan matrix factorization dan deep learning, sehingga mampu menghasilkan rekomendasi yang lebih adaptif. Integrasi informasi tambahan dari sisi pengguna dan produk juga dapat meningkatkan kualitas rekomendasi¹². Penelitian lain menunjukan bahwa Synergistic NeuMF dilaporkan mampu meningkatkan akurasi dan kepuasan pengguna dengan nilai AUC 0.94¹³.

Namun demikian, sebagian besar penelitian tersebut masih berfokus pada karakteristik umum dataset seperti *sparsity* dan *cold start*, sehingga belum menjawab bagaimana perilaku transaksi yang rendah mempengaruhi performa model. Kondisi ini menjadi relevan mengingat penelitian menunjukkan bahwa *repurchase intention* pada platform e-commerce hanya mencapai 49,1%^{14 15}. Sehingga menciptakan kondisi *sparse* yang menantang bagi model rekomendasi.

Untuk mengisi kesenjangan tersebut, penelitian ini berfokus pada perbandingan kinerja dua algoritma rekomendasi berbasis latent factor, yaitu *Matrix Factorization (MF)* dan *Neural Matrix Factorization (NeuMF)*, menggunakan dataset dengan tingkat pembelian ulang yang rendah. Pendekatan ini diharapkan mampu mengidentifikasi model yang paling efektif dalam mengatasi permasalahan data *sparsity*. Selain memberikan kontribusi teoretis terhadap pengembangan algoritma rekomendasi, hasil penelitian ini juga diharapkan dapat memberikan panduan praktis bagi pelaku bisnis dalam memilih dan menerapkan model rekomendasi yang sesuai dengan karakteristik data pengguna, sehingga dapat meningkatkan akurasi rekomendasi, efektivitas strategi pemasaran, dan kepuasan pelanggan.

Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental untuk membandingkan performa dua algoritma rekomendasi, yaitu *Matrix Factorization (MF)* dan *Neural Matrix Factorization (NeuMF)*, dalam menghasilkan rekomendasi produk yang akurat pada platform e-commerce.

Tahap penelitian dimulai dengan data preparation, yang diawali dengan proses *Exploratory Data Analysis (EDA)* untuk memahami isi, struktur, dan karakteristik data sebelum pemodelan¹⁶. EDA dilakukan untuk mengevaluasi kualitas data, mengidentifikasi pola,

¹⁰ Dimitris Kalimeris et al., "Preference Amplification in Recommender Systems," *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, ACM, August 14, 2021, 805–15, <https://doi.org/10.1145/3447548.3467298>.

¹¹ Rosni Lumbantoruan et al., "TopC-CAMF: A Top Context-Based Matrix Factorization Recommender System," *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi* 11, no. 4 (2022): 258–66, <https://doi.org/10.22146/jnteti.v11i4.5399>.

¹² Kyle Ong et al., "Neural Matrix Factorization++ Based Recommendation System," *F1000Research* 10 (October 2021): 1079, <https://doi.org/10.12688/f1000research.73240.1>.


¹³ Gupta Neha et al., "Synergistic Neural Matrix Factorization: Elevating Complementary Product Recommendations in E-Commerce Using Deep Neural Networks," *2024 3rd Edition of IEEE Delhi Section Flagship Conference (DELCON)*, 2024, 1–4, <https://doi.org/10.1109/DELCON64804.2024.10866612>.

¹⁴ Universitas Telkom et al., "E-SERVICE QUALITY, CUSTOMER SATISFACTION, AND REPURCHASE INTENTION: ANALYZING THE IMPACT ON E-COMMERCE PLATFORM," *JURNAL APLIKASI MANAJEMEN* 19, no. 4 (2021): 825–37, <https://doi.org/10.21776/ub.jam.2021.019.04.11>.

¹⁵ Kangming Xu et al., "Intelligent Classification and Personalized Recommendation of E-Commerce Products Based on Machine Learning," *Applied and Computational Engineering* 64, no. 1 (2024): 147–53, <https://doi.org/10.54254/2755-2721/64/20241365>.

¹⁶ Indra Griha Tofik Isa et al., "Exploratory Data Analysis (EDA) dalam Dataset Penerimaan Mahasiswa Baru Universitas XYZ Palembang," *Smart Comp: Jurnalnya Orang Pintar Komputer* 12, no. 3 (2023): 600–609, <https://doi.org/10.30591/smartcomp.v12i3.4125>.

mendeteksi anomali, serta memahami distribusi dan hubungan antarkomponen data melalui berbagai grafik dan visualisasi¹⁷. Dataset yang digunakan merupakan data transaksi penjualan pada platform e-commerce Olist dari tahun 2016 hingga 2018, seperti ditunjukkan pada Gambar 1¹⁸



Gambar 1 Distribusi Transaksi Penjualan

Dataset tersebut terdiri dari tiga tabel utama, yaitu customers, orders, dan order items, dengan total 20 atribut unik. Untuk memperoleh informasi yang lebih lengkap dan relevan, ketiga tabel digabungkan melalui proses join berdasarkan atribut yang saling berhubungan. Selanjutnya dilakukan *k-core filtering* untuk menghapus pengguna dan item dengan jumlah interaksi di bawah nilai ambang (k). Proses ini bertujuan untuk mengurangi noise serta meningkatkan stabilitas model dengan memastikan distribusi interaksi yang lebih seimbang antara pengguna dan item.

Setelah tahap penyaringan, data melalui proses pra-pemrosesan dan pembagian dataset. Pada tahap ini, dataset dibagi menjadi tiga, yaitu *train set*, *validation set*, dan *test set*, menggunakan metode *leave-last-out* berbasis waktu yaitu setiap interaksi terakhir pengguna digunakan sebagai data uji berdasarkan urutan waktu, sehingga mencerminkan prediksi terhadap interaksi masa depan yang sebenarnya¹⁹. Selain itu, diterapkan teknik *negative sampling* untuk menyeimbangkan jumlah interaksi positif dan negatif sehingga model dapat belajar membedakan item yang disukai dan tidak disukai oleh pengguna.

Tahap berikutnya adalah pengembangan dan pelatihan model menggunakan dua pendekatan utama. Matrix Factorization (MF) bekerja dengan mendekomposisi matriks interaksi pengguna–item menjadi dua vektor laten yang mewakili karakteristik pengguna dan item²⁰. Sementara itu, Neural Matrix Factorization (NeuMF) merupakan pengembangan dari MF yang memanfaatkan arsitektur jaringan saraf tiruan untuk menangkap hubungan nonlinier antara pengguna dan item. NeuMF menggabungkan keunggulan Generalized

¹⁷ Mahathir Rahmany et al., “COMPARING TOOLS PROVIDED BY PYTHON AND R FOR EXPLORATORY DATA ANALYSIS,” *IJISCS (International Journal of Information System and Computer Science)* 4, no. 3 (2020): 131, <https://doi.org/10.56327/ijiscs.v4i3.933>.

¹⁸ Sumita Wardani et al., “Analisis Big Data untuk Prediksi Permintaan Produk dalam E-commerce,” *Jurnal Penelitian Teknologi Informasi dan Sains* 3, no. 1 (2025): 74–81, <https://doi.org/10.54066/jptis.v3i1.3066>.

¹⁹ Maurizio Ferrari Dacrema et al., “A Troubling Analysis of Reproducibility and Progress in Recommender Systems Research,” *ACM Transactions on Information Systems* 39, no. 2 (2021): 1–49, <https://doi.org/10.1145/3434185>.

²⁰ Sunil Raj Thota and Saransh Arora, “COLLABORATIVE FILTERING AND KNOWLEDGE GRAPHS FOR DATA DISCOVERY,” *International Research Journal of Modernization in Engineering Technology and Science* 06, no. 05 (2024), <https://doi.org/10.56726/IRJMET56957>.

Matrix Factorization (GMF) dan Multi-Layer Perceptron (MLP) untuk menghasilkan representasi yang lebih kompleks dan akurat²¹.

Setelah model selesai dilatih, dilakukan tahap evaluasi dan visualisasi untuk menilai performa sistem rekomendasi yang dihasilkan. Evaluasi menggunakan dua metrik utama, yaitu *Hit Ratio @10 (HR@10)* dan *Normalized Discounted Cumulative Gain @10 (NDCG@10)*. HR@10 digunakan untuk mengukur seberapa sering item relevan muncul dalam sepuluh rekomendasi teratas, sedangkan NDCG@10 menilai posisi item relevan di dalam daftar rekomendasi, sehingga memberikan gambaran yang lebih detail mengenai kualitas pengurutan rekomendasi²².

Hasil dan Pembahasan

Exploratory Data Analysis (EDA)

Hasil Exploratory Data Analysis (EDA) menunjukkan bahwa penelitian ini menggunakan tiga dataset utama, yaitu orders, order_items, dan customers. Dataset orders dan customers masing-masing berisi 99.441 entri, sementara dataset order_items memiliki 112.650 entri. Perbedaan jumlah data tersebut mengindikasikan bahwa satu transaksi dapat mencakup lebih dari satu item, yang merupakan karakteristik umum dalam platform e-commerce dan berimplikasi pada tingkat variasi interaksi yang harus ditangani oleh model rekomendasi.

Tabel 1 Informasi Dataset

No	Dataset	Jumlah Data	Kolom
1	Customer	99.441	Customer_id, Customer_unique_id, Customer_zip_code, Customer_city, Customer_state
2	Order	99.441	Order_id, Customer_id, Order_status, Order_purchase_timestamp, Order_approved_at, Order_delivered_carrier_date, Order_delivered_customer_date, Order_estimated_delivery_date
3	Order_Items	112.650	Order_id, Order_item_id, Product_id, Seller_id, Shipping_limit_date, Price, Freight_value

Secara struktural, ketiga dataset memiliki atribut yang saling melengkapi. Proses join dilakukan menggunakan atribut order_id dan customer_id untuk membentuk satu tabel interaksi yang menghubungkan pengguna dengan produk yang mereka beli. Langkah ini krusial karena kualitas tabel interaksi sangat bergantung pada integritas relasi antar tabel.

Selain itu, hanya transaksi dengan status *delivered* yang dipertahankan. Pemilihan ini tidak hanya meningkatkan validitas interaksi, tetapi juga mencegah bias data yang dapat muncul jika transaksi yang dibatalkan atau tidak selesai tetap dimasukkan sebagai sinyal preferensi pengguna. Dengan demikian, interaksi yang dianalisis benar-benar merepresentasikan perilaku belanja nyata pengguna.

²¹ Arief Faizin and Isti Surjandari, "Product Recommender System Using Neural Collaborative Filtering for Marketplace in Indonesia," *IOP Conference Series: Materials Science and Engineering* 909, no. 1 (2020): 012072, <https://doi.org/10.1088/1757-899X/909/1/012072>.

²² Xiangnan He et al., "Neural Collaborative Filtering," arXiv:1708.05031, preprint, arXiv, August 26, 2017, <https://doi.org/10.48550/arXiv.1708.05031>.

Raw interactions: 100165
 Jumlah total interaksi: 100165
 Jumlah kolom: 3

Gambar 2 Hasil Preparation

Setelah proses join antar dataset orders, order_items, dan customers, terbentuk sebuah tabel interaksi yang berisi pasangan pengguna dan produk yang telah bertransaksi. Hasil penggabungan tersebut menghasilkan total 100.165 interaksi mentah dengan jumlah kolom sebanyak tiga, yaitu customer_id, product_id, dan order_id. Jumlah interaksi ini menunjukkan volume preferensi eksplisit yang tersedia untuk proses pelatihan model.

Namun, meskipun total interaksi mencapai lebih dari seratus ribu, analisis lebih lanjut menunjukkan bahwa distribusi interaksi tidak merata. Banyak pengguna hanya memiliki satu atau dua transaksi, sementara sejumlah kecil pengguna memiliki frekuensi pembelian yang jauh lebih tinggi. Pola serupa juga terjadi pada item, di mana sebagian besar produk hanya dibeli sekali atau dua kali. Ketidakseimbangan distribusi inilah yang kemudian memperkuat temuan mengenai tingginya tingkat data sparsity pada dataset.

Data Preparation dan Penerapan K-Core Filtering

Untuk menjaga kualitas interaksi dan mengurangi data *sparsity*, maka dilakukan proses k-core filtering dengan ambang batas $k=2$ sehingga hanya pengguna dan item dengan minimal dua transaksi yang dipertahankan dalam dataset. Penyaringan ini berfungsi memastikan bahwa model dilatih menggunakan interaksi yang cukup representatif. Dengan demikian, pengguna maupun item yang sangat jarang muncul yang dapat menimbulkan noise dan memperburuk estimasi representasi laten dihilangkan. Setelah dilakukan proses *k-core filtering* dapat dilihat bahwa terjadi penurunan yang signifikan. Meskipun telah terjadi pengurangan pada jumlah data, proses ini menghasilkan dataset yang lebih padat dan seimbang, dapat dilihat pada tabel 2.

Tabel 2 Hasil K-Core Filtering

No	Metric	Value before	Value After
0	Total Interactions	100.165	3.500
1	Unique Users	93.358	1.651
2	Unique Items	32.216	997

Hasil filtering kemudian digunakan dalam proses pembagian dataset menggunakan pendekatan leave-last-out, yaitu strategi di mana satu interaksi terakhir dari setiap pengguna dijadikan data uji, sedangkan interaksi sebelumnya displit menjadi *train* dan *validation*. Strategi ini dipilih untuk mensimulasikan skenario prediksi dunia nyata, model diminta memprediksi interaksi berikutnya berdasarkan histori sebelumnya, tanpa risiko data *leakage*. Distribusi data setelah pembagian dapat dilihat pada Tabel 3.

Tabel 3 Hasil Set, Validation dan Train

No	Stage	Items	Users	Transaction
0	Df_eval	997	1.651	3.500
1	Train	453	745	833
2	Validation	848	1.651	1.651
3	Test	858	1.651	1.651

Pelatihan Model Rekomendasi dan Evaluasi Hasil

Pembangunan dan pelatihan model rekomendasi menggunakan dua pendekatan yaitu Matrix Factorization (MF) dan Neural Matrix Factorization (NeuMF). Model MF bekerja dengan mendekomposisi matriks interaksi pengguna dan item menjadi dua vektor laten yang merepresentasikan karakteristik pengguna dan produk. Sementara itu, model NeuMF menggabungkan pendekatan MF dengan arsitektur jaringan saraf Multi Layer Perception untuk menangkap hubungan nonlinear antara pengguna dan item.

Kedua model dilatih menggunakan *implicit feedback* dengan jumlah *epoch* sebanyak 5 dan *batch size* sebesar 1024. Untuk menjaga keandalan hasil, dilakukan *multi seed experiment* sebanyak lima kali yaitu *seed* 0-4 agar hasil yang diperoleh lebih stabil dan tidak bergantung pada inisialisasi awal parameter. Evaluasi model dilakukan menggunakan dua metrik utama yaitu Hit Ration (HR@10) dan Normalized Discounted Cumulative Gain (NDCG@10). Hasil pengujian untuk setiap seed disajikan pada Tabel 4, sedangkan nilai rata-rata dan standar deviasi dari masing-masing algoritma dapat dilihat pada Tabel 5.

Tabel 4 Hasil Tiap Sseed

Seed	HR@10_MF	NDCG@10_MF	HR@10_NeuMF	NDCG@10_NeuMF
0	0.057541	0.131720	0.038764	0.098809
1	0.059358	0.138949	0.056935	0.134029
2	0.059358	0.135267	0.048455	0.121625
3	0.059964	0.137835	0.035130	0.102531
4	0.050273	0.119585	0.038764	0.097444


Tabel 5 Hasil Mean dan Standard Deviation

Value	HR@10_MF	NDCG@10_MF	HR@10_NeuMF	NDCG@10_NeuMF
Mean	0.057299	0.132671	0.043610	0.110888
Std	0.004031	0.007826	0.008943	0.016181

Nilai rata-rata HR@10 dan NDCG@10 pada model MF masing-masing mencapai 0,057 dan 0,133, yang secara konsisten lebih tinggi dibandingkan NeuMF dengan nilai 0,044 dan 0,111. Perbedaan ini menunjukkan bahwa MF memiliki kemampuan yang lebih kuat dalam menempatkan item relevan pada sepuluh rekomendasi teratas. Dengan kata lain, struktur representasi laten linear pada MF lebih mampu menangkap pola interaksi pengguna-item dibandingkan pendekatan nonlinear pada NeuMF dalam konteks dataset ini.

Distribusi performa pada Gambar 3 memperlihatkan bahwa penyebaran nilai HR@10 dan NDCG@10 untuk MF jauh lebih rapat, mengindikasikan varian performa antar-seed yang rendah. Stabilitas ini menguatkan temuan bahwa MF memberikan kinerja yang lebih dapat diprediksi dan tidak terlalu dipengaruhi oleh inisialisasi model. Sebaliknya, NeuMF menunjukkan variabilitas yang lebih tinggi dan nilai median yang lebih rendah pada kedua metrik, yang menandakan ketidakstabilan model dalam belajar dari data dengan pola interaksi terbatas.

Hasil ini mengindikasikan adaptif dan lebih tingkat *sparsity*



secara jelas bahwa MF lebih tahan terhadap ekstrem yang

Gambar 3 Distribusi Nilai Terhadap Variasi Seed

muncul akibat rendahnya frekuensi pembelian ulang pada platform e-commerce. Pendekatan linear seperti MF tetap mampu mengekstraksi pola laten tanpa ketergantungan pada volume data yang besar. Sebaliknya, performa NeuMF yang lebih lemah dapat disebabkan oleh kompleksitas arsitektur jaringan sarafnya, yang mengandung lebih banyak parameter dan memerlukan volume interaksi yang besar untuk mencapai generalisasi yang stabil.

Dalam kondisi data yang sangat jarang, kapasitas model yang tinggi justru meningkatkan risiko *overfitting* karena model berupaya menyesuaikan diri dengan pola yang tidak representatif. Temuan ini menegaskan bahwa, dalam kondisi *sparsity* tinggi, model yang lebih sederhana namun efisien seperti MF dapat memberikan performa yang lebih konsisten dibandingkan pendekatan neural yang lebih kompleks.

Kesimpulan

Berdasarkan hasil penerapan dan pengujian, sistem rekomendasi berbasis Matrix Factorization (MF) dan Neural Matrix Factorization (NeuMF) terbukti mampu memetakan hubungan antara pengguna dan produk pada platform e-commerce dengan tingkat pembelian ulang yang rendah. MF menunjukkan performa yang lebih unggul ($HR@10 = 0,057$; $NDCG@10 = 0,133$) dibandingkan NeuMF, yang mengindikasikan kemampuannya dalam menghasilkan rekomendasi yang lebih relevan pada kondisi data yang jarang atau *sparse*. Sementara itu, kinerja NeuMF yang belum optimal dipengaruhi oleh keterbatasan jumlah data dan rendahnya intensitas interaksi pengguna. Penelitian ini juga menegaskan bahwa jumlah interaksi per pengguna maupun per item memiliki pengaruh yang signifikan terhadap kinerja model. Fokus pada frekuensi pembelian ulang dinilai sangat relevan dengan kondisi nyata di e-commerce, di mana sebagian besar pengguna hanya melakukan satu hingga dua kali pembelian. Temuan ini memperlihatkan bahwa superioritas model neural bersifat relatif; keberhasilannya sangat ditentukan oleh kesesuaian antara kompleksitas arsitektur dan kondisi dataset yang dianalisis. Namun, generalisasi hasil perlu diuji pada dataset lain dengan karakteristik *sparsity* berbeda untuk memastikan konsistensi model.

Daftar Pustaka

- Chen, Chong, Min Zhang, Yongfeng Zhang, Yiqun Liu, and Shaoping Ma. "Efficient Neural Matrix Factorization without Sampling for Recommendation." *ACM Transactions on Information Systems* 38, no. 2 (2020): 1–28. <https://doi.org/10.1145/3373807>.
- Endarwati, Esti Tri, Yunita Indriany, Rusdianto Rusdianto, Ni Nyoman Suarniki, and Lusiana Pratiwi. "The Effect of Product Personalization, User Experience, and Consumer Trust on the Level of E-Commerce Consumer Satisfaction in Indonesia."

- Jurnal Bisnisan: Riset Bisnis Dan Manajemen* 6, no. 1 (2024): 163–79. <https://doi.org/10.52005/bisnisan.v6i1.239>.
- Faizin, Arief, and Isti Surjandari. “Product Recommender System Using Neural Collaborative Filtering for Marketplace in Indonesia.” *IOP Conference Series: Materials Science and Engineering* 909, no. 1 (2020): 012072. <https://doi.org/10.1088/1757-899X/909/1/012072>.
- Ferrari Dacrema, Maurizio, Simone Boglio, Paolo Cremonesi, and Dietmar Jannach. “A Troubling Analysis of Reproducibility and Progress in Recommender Systems Research.” *ACM Transactions on Information Systems* 39, no. 2 (2021): 1–49. <https://doi.org/10.1145/3434185>.
- Griha Tofik Isa, Indra, Zulkarnaini Zulkarnaini, Leni Novianti, Febie Elfaladonna, and Suzan Agustri. “Exploratory Data Analysis (EDA) dalam Dataset Penerimaan Mahasiswa Baru Universitas XYZ Palembang.” *Smart Comp: Jurnalnya Orang Pintar Komputer* 12, no. 3 (2023): 600–609. <https://doi.org/10.30591/smartcomp.v12i3.4125>.
- He, Xiangnan, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu, and Tat-Seng Chua. “Neural Collaborative Filtering.” arXiv:1708.05031. Preprint, arXiv, August 26, 2017. <https://doi.org/10.48550/arXiv.1708.05031>.
- Johnson, Nuraeni, Mustika Sufiati Purwanegara, and Nur Budi Mulyono. “Enhancing E-Commerce with Big Data: From Browsing to Buying Through Recommendation Systems.” *International Journal of Entrepreneurship, Business and Creative Economy* 4, no. 1 (2024): 130–45. <https://doi.org/10.31098/ijebce.v4i1.1930>.
- Kalimeris, Dimitris, Smriti Bhagat, Shankar Kalyanaraman, and Udi Weinsberg. “Preference Amplification in Recommender Systems.” *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, ACM, August 14, 2021, 805–15. <https://doi.org/10.1145/3447548.3467298>.
- Neha, Gupta, Vaishali Joshi, Aishwarya Chourey, and Ekta Acharya. “Synergistic Neural Matrix Factorization: Elevating Complementary Product Recommendations in E-Commerce Using Deep Neural Networks.” *2024 3rd Edition of IEEE Delhi Section Flagship Conference (DELCON)*, 2024, 1–4. <https://doi.org/10.1109/DELCON64804.2024.10866612>.
- Nesterov, Vasyil. “ANALYZING USER BEHAVIOR PATTERNS FOR PERSONALIZED RECOMMENDER SYSTEMS IN E-COMMERCE: A LITERATURE REVIEW.” *Automation of Technological and Business Processes* 16, no. 3 (2024): 69–76. <https://doi.org/10.15673/atbp.v16i3.2923>.
- Ong, Kyle, Kok-Why Ng, and Su-Cheng Haw. “Neural Matrix Factorization++ Based Recommendation System.” *F1000Research* 10 (October 2021): 1079. <https://doi.org/10.12688/f1000research.73240.1>.
- Pradnyanita, Ni Kadek Santika, Dewa Ayu Kd Audya Sahya Devanie, and I Made Indra Widiatmika. “Analisis Pengaruh E-Commerce Terhadap Perubahan Pola Konsumsi Masyarakat: Tinjauan Literatur.” *JUWARA: Jurnal Wawasan dan Aksara* 01, no. 01 (2025). <https://doi.org/10.25078/juwara.v1i1.4871>.
- Prayogo, Janny Eka, Aries Suharso, and Adhi Rizal. “Analisis Perbandingan Model Matrix Factorization dan K-Nearest Neighbor dalam Mesin Rekomendasi Collaborative Berbasis Prediksi Rating.” *Jurnal Informatika Universitas Pamulang* 5, no. 4 (2021): 506. <https://doi.org/10.32493/informatika.v5i4.7379>.
- Rahmany, Mahathir, Abdullah Mohd Zin, and Elankovan A Sundararajan. “COMPARING TOOLS PROVIDED BY PYTHON AND R FOR EXPLORATORY DATA ANALYSIS.” *IJISCS (International Journal of Information System and Computer Science)* 4, no. 3 (2020): 131. <https://doi.org/10.56327/ijiscs.v4i3.933>.

- Regita Patricia Agustina, M.Celvin Febrian Syafei, Sunandie Eko Ginanjar, and Siti Aninditya. "Kepercayaan Kepuasan Loyalitas Konsumen Dalam Membeli Barang Di Aplikasi Online Shop." *Jurnal Kajian dan Penalaran Ilmu Manajemen* 2, no. 1 (2024): 261–72. <https://doi.org/10.59031/jkpim.v2i1.351>.
- Rosni Lumbantoruan, Paulus Simanjuntak, Ingrid Aritonang, and Erika Simaremare. "TopC-CAMF: A Top Context-Based Matrix Factorization Recommender System." *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi* 11, no. 4 (2022): 258–66. <https://doi.org/10.22146/jnteti.v11i4.5399>.
- Santosa, Handi Dipo, Leo Manulang, Ramadani Saputra, and Evi Sofiati. "Analysis of the Impact of Online Marketing Campaigns on Consumer Behavior in Indonesia's E-Commerce Market." *Pinisi Discretion Review* 7, no. 2 (2024). <https://doi.org/10.26858/pdr.v7i2.66001>.
- Sumita Wardani, Saidan Sany Lubis, and Rico Wijaya Dewantoro. "Analisis Big Data untuk Prediksi Permintaan Produk dalam E-commerce." *Jurnal Penelitian Teknologi Informasi dan Sains* 3, no. 1 (2025): 74–81. <https://doi.org/10.54066/jptis.v3i1.3066>.
- Suryati, Suryati, Efti Novita Sari, and Eva Yuniarti Utami. "The Effect of Customer Engagement, Content Personalization, and Trust on Purchasing Decisions in Indonesian E-Commerce: A Case Study on the Fashion Industry." *West Science Journal Economic and Entrepreneurship* 1, no. 06 (2023): 134–43. <https://doi.org/10.58812/wsjee.v1i06.453>.
- Thota, Sunil Raj, and Saransh Arora. "COLLABORATIVE FILTERING AND KNOWLEDGE GRAPHS FOR DATA DISCOVERY." *International Research Journal of Modernization in Engineering Technology and Science* 06, no. 05 (2024). <https://doi.org/10.56726/IRJMETS56957>.
- Universitas Telkom, Putu Puspita Sari Sastradi Putri, Cut Irna Setiawati, and Universitas Telkom. "E-SERVICE QUALITY, CUSTOMER SATISFACTION, AND REPURCHASE INTENTION: ANALYZING THE IMPACT ON E-COMMERCE PLATFORM." *JURNAL APLIKASI MANAJEMEN* 19, no. 4 (2021): 825–37. <https://doi.org/10.21776/ub.jam.2021.019.04.11>.
- Xu, Kangming, Huiming Zhou, Haotian Zheng, Mingwei Zhu, and Qi Xin. "Intelligent Classification and Personalized Recommendation of E-Commerce Products Based on Machine Learning." *Applied and Computational Engineering* 64, no. 1 (2024): 147–53. <https://doi.org/10.54254/2755-2721/64/20241365>.