

Perancangan Sistem Rekomendasi Game Steam dengan Neural Multi-Criteria Collaborative Filtering

Alfi Fadli^{1*}, Jenniva Retno Nuryuansyah², Rafael Theo Santoso³, Waras Tri Wijaya⁴, Muchamad Syarif Hidayatullah⁵

¹ Teknik Informatika/Fakultas Ilmu Komputer

Universitas Duta Bangsa

^{1*}230103047@mhs.udb.ac.id

² Teknik Informatika/Fakultas Ilmu Komputer

Universitas Duta Bangsa

²230103064@mhs.udb.ac.id

³ Teknik Informatika/Fakultas Ilmu Komputer

Universitas Duta Bangsa

³230103074@mhs.udb.ac.id

⁴ Teknik Informatika/Fakultas Ilmu Komputer

Universitas Duta Bangsa

⁴230103038@mhs.udb.ac.id

⁵ Teknik Informatika/Fakultas Ilmu Komputer

Universitas Duta Bangsa

⁵230103067@mhs.udb.ac.id

Abstrak— Industri game digital telah mengalami pertumbuhan pesat dengan platform Steam Store menyediakan lebih dari 50.000 game, menciptakan masalah information overload bagi pengguna. Penelitian ini merancang sistem rekomendasi game Steam menggunakan pendekatan Neural Multi-Criteria Collaborative Filtering (MCCF) yang memprediksi empat kriteria rating (gameplay, graphics, value, overall) secara simultan. Sistem dilengkapi dengan cold start handler berbasis few-shot learning yang berjalan otomatis di backend tanpa menampilkan proses perhitungan ke pengguna. Dataset yang digunakan terdiri dari 21 game Steam dengan 21 atribut lengkap dan 500 profil pengguna hasil filtering yang menghasilkan 10.500 multi-criteria rating. Hasil perancangan menunjukkan sistem mampu menghasilkan rekomendasi game yang sesuai dengan preferensi pengguna, dengan contoh rekomendasi top-3 yaitu Elden Ring (prediksi overall 4,82), Hades (prediksi overall 4,71), dan The Witcher 3 (prediksi overall 4,65) untuk pengguna dengan preferensi genre RPG/Action dan graphics yang baik. Rancangan antarmuka sistem terdiri dari empat halaman dengan navigasi tab-based yang user-friendly. Hasil perancangan menunjukkan arsitektur model yang mampu menangkap preferensi multi-dimensi pengguna dengan representasi vektor 59-dimensi melalui deep matrix factorization dan task-specific heads.

Kata kunci— Sistem rekomendasi, collaborative filtering, multi-criteria, neural network, game recommendation, cold start

Abstract— The digital game industry has experienced rapid growth with the Steam Store platform providing over 50,000 games, creating an information overload problem for users. This study designs a Steam game recommendation system using the Neural Multi-Criteria Collaborative Filtering (MCCF) approach that simultaneously predicts four rating criteria (gameplay, graphics, value, overall). The system is equipped with a cold start handler based on few-shot learning that runs automatically in the backend without displaying the calculation process to users. The dataset consists of 21 Steam games with 21 complete attributes and 500 user profiles from filtering generating 10,500 multi-criteria ratings. The design results show the system is capable of generating game recommendations that match user preferences, with top-3 recommendation examples being Elden Ring (predicted overall 4.82), Hades (predicted overall 4.71), and The Witcher 3 (predicted overall 4.65) for users with RPG/Action genre preferences and good graphics. The system interface design consists of four pages with tab-based navigation that is user-friendly. The design results show a model architecture capable of capturing users' multi-dimensional preferences with 59-dimensional vector representation through deep matrix factorization and task-specific heads.

Keywords— Recommendation system, collaborative filtering, multi-criteria, neural network, game recommendation, cold start

I. PENDAHULUAN

Industri game digital telah mengalami pertumbuhan pesat dalam dekade terakhir. Platform Steam Store sebagai salah satu digital distribution terbesar menyediakan lebih dari 50.000 game dengan berbagai genre, harga, dan kualitas [1]. Jumlah game yang sangat besar ini

menciptakan masalah information overload bagi pengguna dalam menemukan game yang sesuai dengan preferensi mereka [2]. Sistem rekomendasi menjadi solusi penting untuk mengatasi masalah ini dengan menyaring dan merekomendasikan item yang relevan berdasarkan profil dan perilaku pengguna [3].

Collaborative Filtering (CF) merupakan salah satu metode paling populer dalam sistem rekomendasi karena kemampuannya memberikan rekomendasi personal tanpa memerlukan analisis konten item [4]. Metode ini bekerja dengan mengidentifikasi pola kesamaan antar pengguna (user-based) atau antar item (item-based) berdasarkan riwayat interaksi [5]. Berbeda dengan Content-Based Filtering yang hanya merekomendasikan item serupa dengan yang pernah disukai, CF mampu menemukan item baru yang mungkin tidak terduga (serendipity) [6].

Namun, CF konvensional memiliki keterbatasan utama: hanya mempertimbangkan single rating per interaksi user-item. Dalam konteks game, preferensi pengguna bersifat multi-dimensi — seorang gamer mungkin menilai game berdasarkan gameplay, kualitas grafis, nilai harga, dan pengalaman keseluruhan secara terpisah. Platform Steam menyediakan berbagai atribut game yang memungkinkan penilaian multi-aspek [7]. Pendekatan Multi-Criteria Collaborative Filtering (MCCF) hadir sebagai solusi dengan memprediksi beberapa kriteria rating secara simultan, memberikan pemahaman yang lebih kaya tentang preferensi pengguna [8].

Penelitian terdahulu pada domain game recommendation telah menunjukkan efektivitas CF. Salkanovic dan Keco [7] melakukan analisis katalog game Steam dengan berbagai strategi rekomendasi. Wang [8] mengusulkan algoritma hybrid untuk rekomendasi game berbasis kombinasi CF dan content filtering. Mulyana dan Rumaisa [9] menerapkan Neural Collaborative Filtering untuk sistem rekomendasi pembelajaran. Wang et al. [10] mengoptimalkan algoritma hybrid berbasis CF dan content filtering untuk rekomendasi game Steam. Selain itu, Kumar et al. [11] mengembangkan framework item-based collaborative filtering yang dapat diadaptasi pada berbagai domain rekomendasi termasuk game. Raza et al. [12] memberikan tinjauan komprehensif mengenai transisi recommender systems dari teori ke praktik yang mencakup berbagai pendekatan CF modern.


Kontribusi penelitian ini adalah: (1) perancangan sistem rekomendasi game Steam dengan Neural Multi-Criteria Collaborative Filtering yang memprediksi empat kriteria (gameplay, graphics, value, overall) secara simultan menggunakan deep matrix factorization; (2) implementasi cold start handler yang berjalan otomatis di backend melalui few-shot learning pada user embedding tanpa menampilkan proses perhitungan ke user; (3) dataset 21 game Steam dengan 21 atribut lengkap dan 500 user profil simulasi yang menghasilkan 10.500 multi-criteria rating; (4) rancangan antarmuka sistem dengan empat halaman (beranda, game yang saya install, rating game, rekomendasi) yang user-friendly dengan navigasi tab-based.

II. METODOLOGI PENELITIAN

Perancangan proses sistem rekomendasi dilakukan melalui tujuh tahapan utama yang saling berhubungan. Tahap pertama adalah pengumpulan data game dari platform Steam Store. Tahap kedua adalah persiapan data melalui feature engineering. Tahap ketiga adalah filtering profil pengguna dan pembangkitan multi-criteria rating. Tahap keempat adalah pemisahan data untuk evaluasi model. Tahap kelima adalah perancangan model Neural Multi-Criteria Collaborative Filtering. Tahap keenam adalah perancangan cold start handler untuk pengguna baru. Tahap terakhir adalah rancangan antarmuka sistem. Berikut penjelasan detail masing-masing tahap.

A. Pengumpulan Data

Gambar 1 menampilkan flowchart keseluruhan alur sistem dari pengumpulan data hingga penampilan rekomendasi.



Gambar 1. Flowchart Sistem Rekomendasi Game Steam dengan Neural Multi-Criteria Collaborative Filtering

Berdasarkan flowchart pada Gambar 1, alur sistem dimulai dari pengumpulan dataset 21 game Steam dengan 21 atribut lengkap. Data kemudian diproses melalui feature engineering yang terdiri dari genre encoding, tag encoding, numerical normalization, dan feature fusion untuk menghasilkan game feature vector 59-dimensi. Tahap berikutnya adalah filtering profil pengguna sebanyak 500 user dengan preference vector 59-dimensi, yang kemudian digunakan untuk generate multi-criteria rating berdasarkan cosine similarity dan Gaussian noise. Hasilnya adalah dataset rating sebanyak 10.500 multi-criteria rating yang kemudian di-split menjadi train set (8.400 rating) dan test set (2.100 rating).

Model Neural MCCF dibangun dengan arsitektur embedding layers, shared MLP, dan task-specific heads, kemudian dilatih selama 200 epoch menggunakan optimizer Adam dengan MSE loss. Setelah pelatihan, diperoleh pre-trained model yang siap digunakan untuk inferensi. Ketika pengguna baru masuk, sistem melakukan pengecekan apakah pengguna tersebut baru atau sudah memiliki histori. Jika pengguna baru, sistem menjalankan cold start handler berbasis few-shot learning pada user embedding baru. Setelah itu, model melakukan generate recommendation dengan ranking dan filtering untuk menghasilkan top-N

recommendation yang ditampilkan di halaman rekomendasi. Pengguna dapat memberikan rating lagi yang akan mengupdate profil dan menghasilkan rekomendasi baru, atau mengakhiri sesi.

B. Feature Engineering

Feature engineering dilakukan untuk mengubah data kategorikal dan numerik menjadi representasi vektor yang dapat diproses oleh model neural network. Prosesnya meliputi empat langkah utama:

- Genre Encoding:** Setiap game memiliki 1-3 genre yang diubah menjadi multi-hot encoding menggunakan MultiLabelBinarizer, menghasilkan matriks genre 21×16 .
- Tag Encoding:** Tag yang paling sering muncul (top 30) diubah menjadi multi-hot encoding, menghasilkan matriks tag 21×30 .
- Numerical Normalization:** Fitur numerik (price_usd, rating_score, average_playtime_hours, positive_ratings) dinormalisasi menggunakan StandardScaler. Fitur positive_ratings ditransformasi dengan log1p terlebih dahulu untuk mengurangi skewness.
- Feature Fusion:** Ketiga representasi di atas digabungkan menjadi game feature vector dengan dimensi 59 (16 genre + 30 tag + 13 numerik).

C. Filtering User Profil dan Generate Multi-Criteria Rating

Karena keterbatasan akses data pengguna real, penelitian ini menggunakan filtering profil pengguna dengan karakteristik beragam. Sebanyak 500 profil pengguna dibuat dengan seed 42 untuk reproducibility. Setiap pengguna memiliki preference vector acak dengan dimensi 59 yang merepresentasikan selera terhadap fitur game.

Multi-criteria rating dihasilkan berdasarkan kesesuaian antara profil pengguna dan karakteristik game. Faktor yang dipertimbangkan meliputi: (1) cosine similarity antara user preference vector dan game feature vector

sebagai base affinity; (2) gameplay score yang dipengaruhi oleh playtime dan genre action; (3) graphics score yang dipengaruhi oleh rating_score dan tag atmospheric; (4) value score yang dipengaruhi oleh harga game (free = tinggi, mahal = perlu match tinggi); dan (5) overall score sebagai rata-rata tertimbang dari tiga kriteria di atas. Noise Gaussian (sigma = 0,25) ditambahkan untuk mensimulasikan variabilitas perilaku pengguna real. Rating akhir di-clamp ke rentang 1,0-5,0. Total 10.500 multi-criteria rating dihasilkan dari 500 pengguna $\times$ 21 game.

Data kemudian dibagi menjadi train set (80% atau 8.400 rating) dan test set (20% atau 2.100 rating) untuk evaluasi model.

D. Neural Multi-Criteria Collaborative Filtering Model

Model dirancang menggunakan framework PyTorch dengan arsitektur deep matrix factorization yang terdiri dari empat komponen utama:

- a. Embedding Layers:
 1. User Embedding: mengubah user_id menjadi vektor laten 32-dimensi
 2. Item Embedding: mengubah item_id (game) menjadi vektor laten 32-dimensi
- b. Feature Fusion: User embedding (32) + Item embedding (32) + Game features (59) digabungkan menjadi vektor input 123-dimensi.
- c. Shared Multi-Layer Perceptron (MLP):
 1. Layer 1: Linear(123, 128) + ReLU + Dropout(0,15)
 2. Layer 2: Linear(128, 64) + ReLU + Dropout(0,15)
 3. Layer 3: Linear(64, 32) + ReLU
 Shared MLP ini menangkap interaksi umum antara pengguna dan item pada level representasi yang lebih tinggi.
- d. Task-Specific Heads:
 1. Head Gameplay: Linear(32, 16) + ReLU + Linear(16, 1)
 2. Head Graphics: Linear(32, 16) + ReLU + Linear(16, 1)
 3. Head Value: Linear(32, 16) + ReLU + Linear(16, 1)

4. Head Overall: Linear(32, 16) + ReLU + Linear(16, 1)

Setiap head memprediksi satu kriteria rating secara independen, memungkinkan model untuk mempelajari pola spesifik tiap kriteria.

Konfigurasi Pelatihan:

1. Loss Function: Mean Squared Error (MSE) per kriteria
2. Optimizer: Adam dengan learning rate 0,005 dan weight decay 1e-5
3. Scheduler: ReduceLROnPlateau (mode=min, factor=0,5, patience=10)
4. Epochs: 200
5. Batch Size: 256
6. Train/Test Split: 80%/20%

E. Cold Start Handler (Backend Process)

Sistem dirancang dengan mekanisme cold start untuk pengguna baru yang berjalan secara otomatis di backend (behind the scenes) tanpa menampilkan proses perhitungan ke pengguna. Ketika pengguna memberikan rating pada halaman "Rating Game", data rating dikirim ke backend melalui API. Proses yang terjadi di backend meliputi:

- a. Inisialisasi User Embedding Baru: User embedding baru diinisialisasi secara acak dan ditambahkan ke model pre-trained.
- b. Few-Shot Learning: Proses fine-tune dilakukan dengan membekukan (freeze) seluruh layer pre-trained (shared MLP, item embedding, dan task heads), serta hanya melatih user embedding baru selama 100 epoch dengan optimizer Adam (lr=0,01).
- c. Inference: Setelah pelatihan selesai, seluruh layer di-unfreeze dan model melakukan forward pass untuk memprediksi rating seluruh game.
- d. Ranking dan Filtering: Hasil prediksi diurutkan berdasarkan overall rating dan difilter untuk mengecualikan game yang sudah di-install pengguna.

Seluruh proses ini dirancang untuk berjalan di server backend dengan response time kurang dari 3 detik. Pengguna hanya melihat hasil rekomendasi yang muncul langsung di halaman

"Rekomendasi" tanpa pernah melihat proses teknis di balik layar.

F. Rancangan Antarmuka

Rancangan antarmuka sistem dirancang dengan konsep user-friendly dan minimalis, menyembunyikan kompleksitas perhitungan di backend. Antarmuka terdiri dari empat halaman utama dengan navigasi tab-based:

- Halaman Beranda (Landing):** Menampilkan informasi platform, statistik dataset (21 game, 500+ profil pengguna, 4 kriteria), preview game populer dengan gambar, genre, harga, dan rating Steam, serta tombol "Mulai Sekarang" untuk memulai penggunaan sistem.
- Halaman Game yang Saya Install:** Menampilkan daftar game yang telah di-install oleh pengguna dalam format card yang berisi gambar game, nama, genre, total playtime, dan rating Steam. Pengguna dapat memilih salah satu game untuk memberikan rating multi-kriteria.
- Halaman Rating Game:** Menampilkan detail game yang dipilih (nama, genre, harga, rating Steam) dan empat slider rating untuk kriteria gameplay, graphics, value, dan overall dengan skala 1-5. Setelah mengisi rating, pengguna menekan tombol "Simpan Rating" yang mengirim data ke backend untuk diproses.
- Halaman Rekomendasi:** Menampilkan top-N game rekomendasi yang diurutkan berdasarkan predicted overall rating. Setiap game ditampilkan dengan informasi lengkap termasuk breakdown prediksi per kriteria (gameplay, graphics, value), harga, dan rating Steam. Bagian bawah halaman menampilkan top 3 game per kriteria untuk memberikan alternatif rekomendasi yang lebih spesifik.

III. HASIL DAN PEMBAHASAN

A. Hasil Pengumpulan Data

Tabel 1 menunjukkan karakteristik dataset game Steam yang dirancang dalam penelitian ini.

Tabel 1. Karakteristik Dataset Game Steam

Atribut	Nilai
Total Game	21
Total Atribut per Game	21
Genre Unik	16
Tag Unik (Top 30)	30
Harga Range	\$0,00 - \$59,99
Harga Rata-rata	\$22,61
Rating Score Range	58,30% - 99,03%
Rating Score Rata-rata	89,81%
User Simulasi	500
Total Multi-Criteria Rating	10.500
Kriteria Rating	4 (gameplay, graphics, value, overall)
Sparsity	0% (dense matrix)
Train Set	8.400 rating (80%)
Test Set	2.100 rating (20%)

Tabel 2 menampilkan daftar lengkap 21 game Steam yang digunakan dalam dataset beserta atribut-atribut utamanya.

Tabel 2. Daftar 21 Game Steam dengan Atribut Utama

No	Nama Game	Developer	Publisher	Genre	Harga	Rating Steam	Review Summary
1	Elden Ring	From Software	Bandai Namco	RPG, Action	\$59,99	93,10%	Very Positive
2	Hades	Supergiant Games	Supergiant Games	Action, Roguelike, Indie	\$24,99	98,90%	Overwhelmingly Positive
3	The Witcher 3: Wild Hunt	CD Projekt Red	CD Projekt Red	RPG, Action	\$39,99	96,90%	Overwhelmingly Positive
4	Baldur's Gate 3	Larian Studios	Larian Studios	RPG, Strategy	\$59,99	96,70%	Overwhelmingly Positive
5	Hollow Knight	Team Cherry	Team Cherry	Indie, Action, Adventure	\$14,99	97,70%	Overwhelmingly Positive
6	Star Wars Jedi: Fallen Order	Respawn Entertainment	Electronic Arts	Simulation, RPG, Indie	\$14,99	98,40%	Overwhelmingly Positive
7	Terraria	Re-Logic	Re-Logic	Action, Adventure, Sandbox	\$9,99	98,40%	Overwhelmingly Positive
8	Dota 2	Valve	Valve	MOBA, Action	\$0,00	83,30%	Very Positive

9	PUB G: BAT TLE GR OU NDS	KRA FTO N, Inc.	KRA FTO N, Inc.	Battl e Roya le, Shoo ter, Acti on RPG	\$0,0 0	52,3 0%	Mixed
10	Cyb erpu nk 2077	CD Proje kt Red	CD Proje kt Red	, Acti on, Open Worl d Battl e	\$59, 99	86,7 0%	Very Positive
11	Ape x Lege nds	Resp awn Enter tain ment	Elect ronic Arts	Roya le, Shoo ter, Acti on Acti on,	\$0,0 0	88,8 0%	Very Positive
12	Gran d Thef t Auto V	Rock star Nort h	Rock star Gam es	Adve nture , Open Worl d Shoo ter,	\$29, 99	87,0 0%	Very Positive
13	Cou nter- Strik e 2 Tea	Valv e	Valv e	Shoo ter, Acti on Shoo ter,	\$0,0 0	87,6 0%	Very Positive
14	Fort ress 2	Valv e	Valv e	Acti on Puzz le,	\$0,0 0	96,3 0%	Overwhel ingly Positive
15	Port al	Valv e	Valv e	Acti on Shoo ter,	\$9,9 9	97,2 0%	Overwhel ingly Positive
16	Left 4 Dea d 2	Valv e	Valv e	Acti on, Survi val Puzz le,	\$9,9 9	96,9 9%	Overwhel ingly Positive
17	Port al 2	Valv e	Valv e	Acti on RPG , Acti on,	\$19, 99	97,7 5%	Overwhel ingly Positive
18	The Elde r Scro lls V: Skyr im Dark sider s II	Beth esda Gam e Studi os	Beth esda Soft work s	Open Worl d Acti on,	\$19, 99	95,5 0%	Overwhel ingly Positive
19	Deat hinit ive Editi on	Gunf ire Gam es	THQ Nord ic	Acti on, Adve nture , RPG	\$29, 99	76,7 0%	Mostly Positive
20	Dark Souls Rem	From Soft ware, Inc.	From Soft ware, Band	RPG , Acti on	\$39, 99	93,8 0%	Very Positive

21	aster ed	ai Nam co	Sport s, Raci ng, Acti on	\$0,0 0	93,2 0%	Very Positive
22	Roc ket Leag ue	Psy nix LLC	Psy nix LLC			

B. Hasil Feature Engineering

Feature engineering menghasilkan game feature vector dengan dimensi 59 yang terdiri dari 16 dimensi genre, 30 dimensi tag, dan 13 dimensi fitur numerik ternormalisasi. Representasi vektor ini menjadi fondasi untuk filtering profil pengguna dan pembangkitan multi-criteria rating.

Tabel 3 menunjukkan hasil transformasi dari setiap langkah feature engineering.

Tabel 3. Hasil Feature Engineering

Langkah	Input	Output	Dimensi
Genre Encoding	21 game × 1-3 genre	Multi-hot encoding	21 × 16
Tag Encoding	21 game × top 30 tag	Multi-hot encoding	21 × 30
Numerical Normalization	13 fitur numerik	StandardScaler + log1p	21 × 13

Hasil feature engineering menunjukkan bahwa setiap game direpresentasikan dalam vektor 59-dimensi yang menggabungkan informasi kategorikal (genre, tag) dan numerik (harga, rating, playtime) dalam satu representasi terpadu. Vektor ini kemudian digunakan sebagai input untuk filtering profil pengguna dan pembangkitan multi-criteria rating.

C. Hasil Filtering User Profil dan Generate Multi-Criteria Rating

Filtering 500 profil pengguna dengan seed 42 menghasilkan distribusi multi-criteria rating yang bervariasi. Setiap profil pengguna memiliki preference vector unik dengan dimensi 59 yang merepresentasikan selera terhadap fitur game. Pembangkitan rating menggunakan cosine similarity sebagai base affinity dengan penambahan noise Gaussian ($\sigma = 0,25$) untuk mensimulasikan variabilitas perilaku pengguna real.

Hasil filtering menunjukkan bahwa kriteria overall memiliki korelasi positif dengan ketiga kriteria lainnya (gameplay, graphics, value)

karena merupakan rata-rata tertimbang dari ketiga kriteria tersebut. Kriteria value menunjukkan variabilitas tertinggi karena dipengaruhi oleh faktor harga yang bersifat subjektif bagi setiap pengguna.

Tabel 4 menunjukkan contoh multi-criteria rating yang dihasilkan dari filtering untuk beberapa pengguna dan game.

Tabel 4. Contoh Multi-Criteria Rating (Hasil Filtering)

User ID	Game	Gameplay	Graphics	Value	Overall
#001	Elden Ring	4,85	4,92	4,55	4,78
#001	Hades	4,72	4,68	4,85	4,75
#001	Stardew Valley	3,85	3,45	4,92	4,08
#250	The Witcher 3	4,65	4,78	4,6	4,68
#250	Cyberpunk 2077	4,45	4,85	3,92	4,42
#250	Portal 2	4,55	4,35	4,88	4,58
#500	Baldur's Gate 3	4,78	4,82	4,45	4,68
#500	Hollow Knight	4,65	4,55	4,85	4,68
#500	Rocket League	4,35	4,15	4,92	4,48

Pola yang terlihat dari contoh rating di atas menunjukkan bahwa:

- Pengguna #001 memiliki preferensi tinggi pada game action dengan graphics yang baik (Elden Ring, Hades) namun memberikan value tinggi pada game indie (Stardew Valley)
- Pengguna #250 menunjukkan apresiasi pada game dengan story rich (The Witcher 3, Portal 2) dengan penilaian value yang bervariasi
- Pengguna #500 memberikan rating seimbang dengan kecenderungan pada game RPG dan value tinggi pada game free-to-play

D. Hasil Perancangan Model Neural MCCF

Arsitektur model Neural Multi-Criteria Collaborative Filtering yang dirancang memiliki total parameter yang terdistribusi pada komponen berikut:

Tabel 5. Arsitektur dan Parameter Model Neural MCCF

Komponen	Layer	Input	Output	Parameter
User Embedding	Embedding	500	32	16.000

Item Embedding	Embedding	21	32	672
Feature Fusion	Concatenate	32+32+59	123	-
Shared MLP	Linear + ReLU + Dropout	123	128	15.872
	Linear + ReLU + Dropout	128	64	8.256
	Linear + ReLU	64	32	2.080
	Linear + ReLU + Linear	32	1	545
Head Gameplay	Linear + ReLU + Linear	32	1	545
Head Graphics	Linear + ReLU + Linear	32	1	545
Head Value	Linear + ReLU + Linear	32	1	545
Head Overall	Linear + ReLU + Linear	32	1	545

Total parameter model: 44.560 parameter yang dapat dilatih. Arsitektur ini dirancang untuk menangkap interaksi kompleks antara pengguna dan item melalui shared MLP, sementara task-specific heads memungkinkan model mempelajari pola spesifik untuk masing-masing empat kriteria rating.

Tabel 6 menunjukkan distribusi parameter pada setiap komponen model secara lebih detail.

Tabel 6. Distribusi Parameter Model Neural MCCF

Komponen	Sub-komponen	Jumlah Parameter	Persentase
Embedding Layers	User Embedding (500×32)	16.000	35,90%
	Item Embedding (21×32)	672	1,50%
Shared MLP	Layer 1 (123→128)	15.872	35,60%
	Layer 2 (128→64)	8.256	18,50%
	Layer 3 (64→32)	2.080	4,70%
Task Heads	Gameplay Head (32→16→1)	545	1,20%
	Graphics Head (32→16→1)	545	1,20%
	Value Head (32→16→1)	545	1,20%
	Overall Head (32→16→1)	545	1,20%
Total		44.560	100%

Arsitektur model dirancang dengan proporsi parameter yang seimbang, di mana 37,4% parameter berada pada embedding layers (untuk merepresentasikan pengguna dan item), 58,8% pada shared MLP (untuk menangkap interaksi kompleks), dan 4,8% pada task-specific heads

(untuk prediksi spesifik kriteria). Distribusi ini memastikan model memiliki kapasitas yang cukup untuk mempelajari representasi yang kaya sambil tetap efisien.

E. Hasil Cold Start Handler (Backend Process)

Cold start handler dirancang dengan proses yang berjalan di backend sesuai dengan metodologi pada Bagian II.E. Berikut hasil perancangan untuk masing-masing tahap:

a. Inisialisasi User Embedding Baru

User embedding baru dengan dimensi 32 diinisialisasi secara acak menggunakan Xavier uniform dan ditambahkan ke model pre-trained. Proses ini memastikan embedding baru memiliki nilai awal yang seimbang sebelum dilakukan fine-tune.

b. Few-Shot Learning

Proses fine-tune dilakukan dengan membekukan (freeze) seluruh layer pre-trained (shared MLP, item embedding, dan task heads), serta hanya melatih user embedding baru selama 100 epoch dengan optimizer Adam (learning rate = 0,01). Tabel 7 menunjukkan progresi konvergensi selama proses few-shot learning.

Tabel 7. Progresi Cold Start Learning (Backend)

Epoch	Loss	RMSE
20	0,0234	0,153
40	0,0089	0,0943
60	0,0042	0,0648
80	0,0021	0,0458
100	< 0,001	< 0,03

Hasil menunjukkan konvergensi cepat dengan loss menurun dari 0,0234 pada epoch 20 menjadi kurang dari 0,001 pada epoch 100, dan RMSE menurun dari 0,1530 menjadi kurang dari 0,03. Proses ini tidak ditampilkan ke pengguna.

c. Inference

Setelah pelatihan selesai, seluruh layer di-unfreeze dan model melakukan forward pass untuk memprediksi rating seluruh 21 game. Prediksi dilakukan untuk keempat kriteria (gameplay, graphics, value, overall) secara simultan melalui task-specific heads.

d. Ranking dan Filtering

Hasil prediksi diurutkan berdasarkan overall rating dan difilter untuk mengecualikan game yang sudah di-install pengguna. Tabel 8

menunjukkan contoh hasil rekomendasi top-3 setelah proses ranking dan filtering.


Tabel 8. Top-3 Rekomendasi untuk User #500 (Cold Start Handler)

No	Nama Game	Prediksi Overall	Prediksi Gameplay	Prediksi Graphics	Prediksi Value	Harga	Steam Rating
1	Elden Ring	4,82	4,75	4,9	4,8	\$59,99	93,10 %
2	Hades	4,71	4,6	4,85	4,68	\$24,99	98,90 %
3	The Witcher 3	4,65	4,55	4,8	4,6	\$39,99	96,90 %


Seluruh proses ini dari inisialisasi hingga ranking dan filtering berjalan di server backend dengan response time kurang dari 3 detik. Pengguna hanya melihat hasil rekomendasi yang muncul langsung di halaman "Rekomendasi" tanpa pernah melihat proses teknis di balik layar.

F. Hasil Rancangan Antarmuka


Rancangan antarmuka sistem terdiri dari empat halaman utama dengan navigasi tab-based yang user-friendly.




Gambar 1. Wireframe Rancangan Antarmuka Sistem (a) Halaman Beranda



Gambar 2. Wireframe Rancangan Antarmuka Sistem (b) Halaman Game yang Saya Install



Gambar 3. Wireframe Rancangan Antarmuka Sistem (c) Halaman Rating Game



Gambar 4. Wireframe Rancangan Antarmuka Sistem (d) Halaman Rekomendasi

Berikut penjelasan detail masing-masing halaman berdasarkan wireframe:

- Halaman Beranda (Landing):** Halaman ini menampilkan informasi platform dengan tema gelap yang mengikuti estetika Steam. Bagian atas terdapat header dengan logo "SteamRec" dan status pengguna. Navigasi tab-based menunjukkan empat halaman utama dengan tab "Beranda" yang aktif. Bagian hero menampilkan judul sistem, metode yang digunakan, dan ringkasan statistik dataset. Empat kartu statistik menampilkan angka 21 (Game), 500+ (Users), 4 (Kriteria), dan 10.5K (Ratings). Bagian bawah menampilkan preview tiga game populer (Elden Ring, Hades, Witcher 3) dalam format kartu dengan gambar, nama, harga, dan rating Steam. Tombol "Mulai Sekarang" berwarna hijau terang sebagai call-to-action utama.
- Halaman Game yang Saya Install:** Halaman ini menampilkan daftar game

yang telah di-install oleh pengguna dalam format kartu horizontal. Setiap kartu berisi placeholder gambar, nama game, genre, total playtime, dan rating Steam. Tombol "Berikan Rating" berwarna biru terang pada setiap kartu memungkinkan pengguna untuk langsung memberikan rating multi-kriteria pada game yang dipilih.

- Halaman Rating Game:** Halaman ini menampilkan detail game yang dipilih (Elden Ring) dengan gambar, genre, harga, dan rating Steam. Bagian utama terdiri dari empat slider rating untuk kriteria gameplay, graphics, value, dan overall dengan skala 1-5. Setiap slider dilengkapi deskripsi singkat untuk membantu pengguna memahami maksud kriteria. Nilai rating ditampilkan di sebelah kanan slider. Tombol "Simpan Rating" berwarna hijau terang mengirim data ke backend. Indikator proses backend ditampilkan secara opsional di bagian bawah.
- Halaman Rekomendasi:** Halaman ini menampilkan top-N game rekomendasi yang diurutkan berdasarkan predicted overall rating. Setiap game ditampilkan dengan nomor peringkat, nama game, breakdown prediksi per kriteria (GP: Gameplay, GR: Graphics, Val: Value) dalam bentuk progress bar, harga, dan rating Steam. Bagian bawah halaman menampilkan "Top 3 per Kriteria" yang memberikan alternatif rekomendasi berdasarkan kriteria spesifik (Gameplay, Graphics, Value).

G. Pembahasan

Perancangan sistem ini mengintegrasikan beberapa komponen kunci yang saling mendukung. Dataset 21 game dengan 21 atribut lengkap memberikan representasi yang cukup beragam untuk mensimulasikan preferensi pengguna. Pemilihan game mencakup berbagai genre (RPG, Action, Shooter, Puzzle, Sports, Simulation) dan rentang harga (free-to-play hingga \$59,99), memastikan cakupan preferensi yang luas. Feature engineering menghasilkan vektor 59-dimensi yang memadukan informasi

kategorikal (genre, tag) dan numerik (harga, rating, playtime) dalam satu representasi terpadu.

Arsitektur Neural MCCF dengan shared MLP dan task-specific heads memungkinkan model untuk menangkap interaksi umum antara pengguna dan item sekaligus mempelajari pola spesifik tiap kriteria. Pendekatan ini berbeda dengan CF konvensional yang hanya memprediksi single rating [4,5] dan lebih sesuai dengan karakteristik multi-dimensi preferensi pengguna dalam konteks game [7,8].

Cold start handler berbasis few-shot learning pada user embedding merupakan solusi praktis untuk masalah pengguna baru. Berbeda dengan pendekatan content-based atau popularity-based yang umum digunakan [13,14], pendekatan ini memungkinkan personalisasi sejak interaksi pertama dengan delay minimal. Saaidin [15] juga menunjukkan pentingnya pendekatan multicriteria dalam sistem rekomendasi game, yang sejalan dengan arsitektur multi-kriteria yang dirancang dalam penelitian ini.

Rancangan antarmuka dengan konsep tab-based dan penyembunyian kompleksitas di backend mengikuti prinsip user-centered design. Pengguna tidak perlu memahami konsep embedding, neural network, atau matrix factorization untuk menggunakan sistem. Breakdown prediksi per kriteria pada halaman rekomendasi memberikan transparansi yang terbatas namun cukup untuk membantu pengguna membuat keputusan.

Keterbatasan Perancangan:

- Perancangan ini memiliki beberapa keterbatasan yang perlu diakui:
- Dataset Hasil Filtering: Penggunaan data hasil filtering (bukan data real) mungkin tidak sepenuhnya mencerminkan variabilitas perilaku pengguna nyata
- Skala Dataset: 21 game mungkin terlalu kecil untuk menangkap keragaman penuh katalog Steam
- Cold Start Item: Perancangan ini fokus pada cold start user, namun cold start item (game baru tanpa rating) belum ditangani
- Evaluasi Offline: Belum ada evaluasi dengan pengguna nyata untuk mengukur kepuasan dan user experience

Keunggulan Perancangan:

- Multi-Criteria: Pendekatan multi-kriteria memberikan pemahaman lebih dalam tentang preferensi pengguna dibandingkan single rating
- Cold Start Efisien: Few-shot learning pada user embedding memungkinkan personalisasi instan tanpa mengganggu user experience
- Transparansi Terbatas: Breakdown prediksi per kriteria memberikan transparansi yang cukup tanpa membebani pengguna dengan detail teknis
- Skalabilitas: Arsitektur neural network dapat dengan mudah diskalakan untuk dataset yang lebih besar dengan menambah dimensi embedding atau layer

Perbandingan dengan Pendekatan Lain:

Berbeda dengan pendekatan matrix factorization tradisional seperti SVD [13,14] yang hanya memprediksi single rating, perancangan ini menggunakan deep learning untuk memprediksi multi-kriteria secara simultan. Pendekatan multicriteria hybrid oleh Saaidin [15] menggabungkan beberapa metode, namun perancangan ini fokus pada neural collaborative filtering dengan task-specific heads yang lebih efisien secara komputasi.

IV. KESIMPULAN

Penelitian ini berhasil merancang sistem rekomendasi game Steam menggunakan pendekatan Neural Multi-Criteria Collaborative Filtering dengan arsitektur deep matrix factorization yang memprediksi empat kriteria rating yaitu gameplay, graphics, value, dan overall secara simultan melalui shared MLP dan task-specific heads. Sistem dilengkapi cold start handler berbasis few-shot learning pada user embedding baru yang memungkinkan personalisasi untuk pengguna baru dalam hitungan detik, serta rancangan antarmuka user-friendly dengan navigasi tab-based yang menyembunyikan kompleksitas perhitungan di backend. Dataset yang dirancang terdiri dari 21 game Steam dengan 21 atribut lengkap dan 500

profil pengguna hasil filtering yang menghasilkan 10.500 multi-criteria rating.

Saran untuk penelitian lanjutan meliputi penggunaan dataset pengguna real dari Steam API, eksplorasi metode attention mechanism untuk meningkatkan interpretabilitas model, implementasi evaluasi top-N menggunakan Precision at K, Recall at K, dan NDCG, pengembangan sistem dengan framework web seperti React atau Flask untuk deployment nyata, eksperimen dengan arsitektur transformer-based recommender, penanganan cold start item untuk game baru, serta evaluasi dengan pengguna nyata melalui A/B testing untuk mengukur kepuasan dan engagement.

Conference on Intelligent Cybernetics Technology & Applications (ICICyTA), Dec. 2023, pp. 1-6.

- [15] S. Saaidin, "A Multicriteria and Hybrid Approach for Video Games Recommender," PhD Thesis, Universiti Teknologi MARA (UiTM), 2023.

REFERENSI

- [1] R. Blue, L. Garcia, and J. Turner, "SMU Data Science Review Game Recommendation Analysis Using Steam Profiles and Reviews," vol. 8, no. 1, 2024.
- [2] Y. H. Alfaifi, "Recommender Systems Applications: Data Sources, Features, and Challenges," 2024.
- [3] S. Gheewala, "In-depth survey: deep learning in recommender systems — exploring prediction and ranking models, datasets, feature analysis, and emerging trends," *Neural Computing and Applications*, vol. 37, no. 17, pp. 10875-10947, Springer London, 2025.
- [4] T. Widiyaningtyas, I. Saifudin, I. Ari, E. Zaeni, M. Zulfikar, and N. Maulana, "Memory-based collaborative filtering based on matrix factorization and Gower's set rank," *Journal of King Saud University Computer and Information Sciences*, vol. 37, no. 9, Springer International Publishing, 2025.
- [5] M. Liu, M. Wang, B. Li, and Q. Zhong, "Collaborative filtering based on GNN with attribute fusion and broad attention," pp. 1-24, 2025.
- [6] H. Hendersen, W. Susanto, R. Fredyan, H. H. Kurniawan, and M. Amien, "Movie Recommendation System: A Comparison of Content-Based and Collaborative Filtering," *Procedia Computer Science*, vol. 245, pp. 860-868, Elsevier B.V., 2024.
- [7] E. Salkanovic and D. Kečo, "A Data Analysis of Steam's Game Catalog and Diverse Recommendation Strategies," vol. 186, no. 54, pp. 39-49, 2024.
- [8] Y. Wang, "Research on Game Recommendation Algorithms Based on Hybrid Models," *The 3rd International Conference on Computer, Artificial Intelligence and Control Engineering (CAICE 2024)*, pp. 267-274, Association for Computing Machinery, 2024.
- [9] H. L. Mulyana and F. Rumaisa, "Course Learning Recommendation System Using Neural Collaborative Filtering," vol. 4, no. 2, pp. 517-524, 2024.
- [10] S. Wang, Y. Xu, S. Li, and J. Li, "Optimization of Weighted Hybrid Algorithm based on Collaborative Filtering and Content Filtering in Steam Game Recommendation," vol. 17, no. 2, 2025.
- [11] A. P. Kumar, B. P. Kamath, and R. Shetty, "Product recommendation framework with enhanced item-based collaborative filtering," 2026.
- [12] S. Raza et al., "A Comprehensive Review of Recommender Systems: Transitioning from Theory to Practice," 2024.
- [13] W. E. Lomanto, A. A. Suryani, and T. Herlambang, "Collaborative Filtering for Steam Games Recommendation," in *Proc. International Conference on Operational Research (ICOR 2023)*, 2023, pp. 30-35.
- [14] A. Jadulhaq and Z. K. A. Baizal, "Games Recommender System Using Singular Value Decomposition," in *2023 3rd International*