

BAB II

LANDASAN TEORI

2.1 Tinjauan Pustaka

2.1.1 Cryptocurrency

Cryptocurrency adalah aset digital yang dirancang untuk berfungsi sebagai medium pertukaran yang menggunakan kriptografi untuk mengamankan transaksi, mengontrol pembuatan unit tambahan, dan memverifikasi transfer aset tanpa otoritas pusat (Atree & Tripathy, 2025). Secara teknis, cryptocurrency memanfaatkan teknologi blockchain untuk mencapai desentralisasi, transparansi, dan immutabilitas dalam proses transaksi digital (Himeur et al., 2022; Sunny et al., 2022).

Berbeda dengan mata uang fiat tradisional, cryptocurrency memiliki karakteristik unik seperti desentralisasi, transparansi, keamanan kriptografi, volatilitas tinggi, dan inovasi berkelanjutan (Atree & Tripathy, 2025; Jain, 2022). Ekosistem cryptocurrency telah berkembang pesat dengan munculnya ribuan proyek dengan berbagai fungsi dan kasus penggunaan, mulai dari mata uang digital (Bitcoin), platform kontrak pintar (Ethereum), hingga proyek DeFi (Decentralized Finance), NFT (Non-Fungible Tokens), dan GameFi (Game Finance) (Q. Yang et al., 2023).

2.1.2 Sistem Rekomendasi

Sistem rekomendasi adalah teknologi penyaringan informasi yang memprediksi preferensi atau peringkat yang akan diberikan pengguna terhadap

suatu item (Kumar et al., 2021). Sistem ini memanfaatkan algoritma dan data untuk menawarkan saran yang dipersonalisasi kepada pengguna, membantu mereka menemukan item yang relevan di tengah jumlah informasi yang besar.

Menurut (Kulkarni et al., 2023), terdapat beberapa pendekatan utama dalam sistem rekomendasi:

1. Content-based Filtering: Merekomendasikan item berdasarkan kesamaan dengan item yang disukai pengguna sebelumnya
2. Collaborative Filtering: Membuat rekomendasi berdasarkan perilaku dan preferensi pengguna lain yang mirip
3. Knowledge-based: Menggunakan pengetahuan eksplisit tentang item, preferensi pengguna, dan kriteria rekomendasi
4. Hybrid Approaches: Menggabungkan dua atau lebih metode untuk meningkatkan kualitas rekomendasi

Dalam konteks investasi cryptocurrency, sistem rekomendasi memainkan peran penting dalam membantu investor mengidentifikasi peluang potensial di antara ribuan aset digital yang tersedia.

2.1.3 Collaborative Filtering (CF)

Collaborative filtering merupakan salah satu teknik yang paling umum digunakan dalam sistem rekomendasi. Teknik ini sebagaimana dijelaskan oleh (Kumar et al., 2021; Majumdar, 2024) beroperasi berdasarkan prinsip bahwa pengguna dengan preferensi atau perilaku serupa cenderung menyukai item yang sama. Tidak seperti pendekatan content-based filtering yang mengandalkan

karakteristik spesifik item, collaborative filtering memanfaatkan kebijaksanaan kolektif dari banyak pengguna untuk mengidentifikasi pola dan hubungan antar pengguna dan item.

Dalam konteks sistem rekomendasi cryptocurrency, collaborative filtering memungkinkan sistem untuk mempelajari preferensi investasi pengguna berdasarkan interaksi historis mereka dengan berbagai proyek, serta interaksi pengguna serupa lainnya, untuk kemudian memberikan rekomendasi yang dipersonalisasi.

Menurut (Majumdar, 2024), terdapat dua pendekatan utama dalam CF:

1. Memory-based CF: Menggunakan seluruh database pengguna-item untuk menghasilkan prediksi
 - User-based: Mencari pengguna serupa dan merekomendasikan item yang mereka sukai
 - Item-based: Mencari item serupa berdasarkan pola penilaian pengguna
2. Model-based CF: Mengembangkan model berdasarkan data pelatihan untuk membuat prediksi
 - Matrix Factorization: SVD (Singular Value Decomposition), NMF (Non-negative Matrix Factorization)
 - Neural Network-based: Menggunakan deep learning untuk menangkap pola interaksi kompleks

Implementasi CF tradisional menggunakan matriks peringkat pengguna-item $R \in \mathbb{R}^{m \times n}$ di mana m adalah jumlah pengguna dan n adalah jumlah item. Elemen r_{ui} merepresentasikan peringkat atau preferensi pengguna u terhadap item i .

$$r_{ui} = \begin{cases} \text{rating atau preferensi, jika tersedia} \\ ? & \text{jika tidak tersedia} \end{cases} \quad (1)$$

Dalam user-based CF, prediksi rating \hat{r}_{ui} untuk pengguna u dan item i dapat dihitung sebagai:

$$\hat{r}_{ui} = \bar{r}_u + \frac{\sum_{v \in N(u)} \text{sim}(u,v) \times (r_{vi} - \bar{r}_v)}{\sum_{v \in N(u)} |\text{sim}(u,v)|} \quad (2)$$

Di mana r_{ui} adalah rating yang diprediksi untuk pengguna u dan item i , \bar{r}_u adalah rata-rata rating yang diberikan oleh pengguna u dan $N(u)$ adalah kumpulan pengguna yang serupa dengan u . Selain itu, $\text{sim}(u, v)$ adalah nilai similaritas antara pengguna u dan v , yang menunjukkan sejauh mana dua pengguna memiliki kesamaan preferensi. Komponen r_{vi} adalah rating yang diberikan oleh pengguna v terhadap item i dan \bar{r}_v adalah rata-rata rating yang diberikan oleh pengguna v . Rumus ini menggabungkan informasi rating yang diberikan oleh pengguna-pengguna yang serupa dengan pengguna u , dengan penyesuaian terhadap rating rata-rata masing-masing pengguna.

Implementasi CF pada domain cryptocurrency menghadapi tantangan unik seperti data yang sangat sparse, cold-start problem, dan volatilitas tinggi yang memengaruhi preferensi pengguna.

2.1.4 Feature-Enhanced Collaborative Filtering

Menindaklanjuti pembahasan (Kumar et al., 2021; Majumdar, 2024) tentang jenis-jenis collaborative filtering dalam sistem rekomendasi, Feature-Enhanced Collaborative Filtering (FECF) memperluas pendekatan CF tradisional dengan mengintegrasikan informasi fitur atau metadata dari item dan/atau pengguna dalam proses rekomendasi (Mukti & Baizal, 2025). Pendekatan ini mengatasi keterbatasan utama CF tradisional seperti masalah cold-start dan sparsity.

FECF secara fundamental merupakan jembatan antara collaborative filtering dan content-based filtering, dimana FECF mengintegrasikan kekuatan utama dari content-based filtering yaitu analisis fitur item, ke dalam framework collaborative filtering (Wang et al., 2024). Berbeda dengan CF tradisional yang hanya mengandalkan matriks interaksi pengguna-item yang sparse, FECF memanfaatkan kekayaan informasi dari fitur item (content-based) untuk meningkatkan representasi laten dari pengguna dan item.

(Fischer et al., 2023; W. Yang et al., 2022) menjelaskan bahwa Feature-Enhanced bekerja dengan menggabungkan dua jenis informasi:

1. Interaksi pengguna-item: Seperti pada CF tradisional (peringkat, klik, pembelian dll.)
2. Informasi fitur: Karakteristik item dan atribut pengguna

Algoritma Feature-Enhanced CF umumnya mengimplementasikan matrix factorization yang diperkaya dengan regularisasi berbasis fitur atau embedding

khusus untuk representasi fitur. Dalam Feature-Enhanced CF, model matrix factorization diperluas dengan mempertimbangkan fitur item, menghasilkan formula prediksi:

$$\hat{r}_{ui} = P_u^T q_i + P_u^T W x_i + b_u + b_i + \mu \quad (3)$$

Di mana P_u adalah vektor laten yang merepresentasikan preferensi pengguna u terhadap item i , dan q_i adalah vektor laten yang menggambarkan karakteristik laten dari item i . Selain itu, x_i adalah vektor fitur dari item i , di mana W adalah matriks yang memetakan ruang fitur ke ruang laten pengguna. b_u dan b_i masing-masing adalah bias pengguna dan bias item yang mencerminkan kecenderungan pengguna dalam memberikan rating dan popularitas item tersebut. Terakhir, μ adalah rata-rata global dari seluruh rating yang ada dalam sistem, yang digunakan sebagai baseline sebelum penyesuaian oleh faktor-faktor lainnya.

Dalam formula prediksi FECEF, komponen $P_u^T W x_i$ secara langsung merepresentasikan elemen content-based, dimana vektor fitur item x_i (karakteristik konten) dipetakan ke dalam ruang laten pengguna melalui matriks W (Kumar et al., 2021; Majumdar, 2024). Pendekatan gabungan ini memungkinkan sistem untuk memberikan rekomendasi yang akurat bahkan ketika data interaksi terbatas, karena dapat memanfaatkan kesamaan berbasis konten antara item-item yang belum pernah berinteraksi dengan pengguna.

Keuntungan utama Feature-Enhanced CF meliputi kemampuan yang lebih baik untuk menangani item baru dengan informasi fitur (cold-start), peningkatan akurasi rekomendasi dengan mengintegrasikan konteks tambahan, dan kemampuan

untuk menjelaskan rekomendasi berdasarkan fitur yang relevan (Mukti & Baizal, 2025).

(Karabila et al., 2023) menekankan bahwa integrasi informasi tambahan seperti ulasan pengguna ke dalam collaborative filtering dapat mengatasi keterbatasan sistem rekomendasi tradisional yang hanya mengandalkan rating numerik, yang seringkali tidak cukup untuk memberikan saran yang dipersonalisasi dan akurat.

Dalam konteks cryptocurrency, Feature-Enhanced CF dapat memanfaatkan fitur-fitur penting seperti kategori (DeFi, NFT, Metaverse), chain (Ethereum, Binance Smart Chain), metrik pasar (kapitalisasi pasar, volume), dan indikator sosial (Himeur et al., 2022), untuk meningkatkan kualitas rekomendasi.

2.1.5 Neural Collaborative Filtering

Neural Collaborative Filtering (NCF) adalah pendekatan modern dalam sistem rekomendasi yang memanfaatkan kekuatan deep learning untuk memodelkan interaksi kompleks antara pengguna dan item. NCF mengatasi keterbatasan model matrix factorization tradisional dengan kemampuannya menangkap hubungan non-linear (Nugroho et al., 2024).

NCF menggunakan neural networks untuk mempelajari representasi latent dari pengguna dan item, serta fungsi interaksi mereka. Arsitektur umum NCF menurut (Nugroho et al., 2024) meliputi:

1. Input Layers: Embedding vectors untuk pengguna dan item

2. Hidden Layers: Multiple dense layers dengan fungsi aktivasi non-linear
3. Output Layer: Prediksi skor preferensi/interaksi

Dalam NCF, prediksi rating atau preferensi \hat{y}_{ui} untuk pasangan pengguna-item (u, i) dimodelkan sebagai:

$$\hat{y}_{ui} = f(P^T v_u, Q^T v_i | P, Q, \Theta_f) \quad (4)$$

Di mana v_u dan v_i adalah representasi one-hot encoding dari pengguna u dan item i , masing-masing digunakan untuk mengekstrak embedding dari matriks proyeksi. Matriks $R \in \mathbb{R}^{M \times K}$ dan $Q \in \mathbb{R}^{N \times K}$ merupakan matriks embedding yang memetakan pengguna dan item ke dalam ruang laten berdimensi K , dengan M dan N berturut-turut sebagai jumlah total pengguna dan item. Parameter Θ_f adalah kumpulan parameter yang digunakan oleh model neural network, sedangkan f adalah fungsi interaksi non-linear yang dipelajari oleh neural network untuk menghasilkan prediksi akhir terhadap interaksi pengguna dan item.

Sebagai perluasan, Generalized Matrix Factorization (GMF) dalam NCF dimodelkan sebagai:

$$\hat{y}_{ui}^{GMF} = a_{out}(h^T(p_u \odot q_i)) \quad (5)$$

Dan Multi-Layer Perceptron (MLP) dimodelkan sebagai:

$$\hat{y}_{ui}^{MLP} = a_{out}(h^T \phi_L(\dots \phi_2(\phi_1([p_u, q_i]))) \quad (6)$$

Di mana p_u dan q_i merupakan vektor embedding dari pengguna u dan item i , yang merepresentasikan fitur laten mereka. Kedua vektor ini digabungkan

melalui operasi konkatenasi dan kemudian diproses secara berlapis oleh fungsi aktivasi ϕ_l pada setiap layer l dalam jaringan saraf multi-layer perceptron (MLP). Fungsi aktivasi output a_{out} diterapkan pada hasil akhir untuk menghasilkan skor prediksi interaksi antara pengguna dan item. Struktur ini memungkinkan model untuk menangkap hubungan non-linear yang kompleks dalam data interaksi pengguna-item.

Varian utama NCF antara lain Generalized Matrix Factorization (GMF) dan Multi-Layer Perceptron (MLP yang menggabungkan kedua model tersebut (Mukherjee et al., 2024; Nugroho et al., 2024). Model-model ini dapat dikembangkan lebih lanjut dengan mekanisme attention, residual connections, dan normalization layers.

Pendekatan hybrid yang menggabungkan NCF dengan feature enhancement telah terbukti efektif dalam domain aset digital blockchain. Penelitian (Aydogdu & Aydin, 2024) menunjukkan bahwa implementasi hybrid NCF untuk rekomendasi NFT berhasil mengatasi masalah sparsitas data dan cold-start problem melalui integrasi on-chain analytics dengan collaborative filtering, mencapai peningkatan performa signifikan dibandingkan metode tradisional.

Dalam konteks cryptocurrency, NCF dapat memanfaatkan pola transaksi historis, aktivitas portofolio, dan interaksi pengguna-proyek untuk memprediksi preferensi investasi masa depan (Drammeh & Li, 2023).

2.1.6 Metrik Popularitas dan Tren Investasi Cryptocurrency

Metrik popularitas dan tren investasi merupakan indikator penting yang membantu investor mengidentifikasi peluang potensial di pasar cryptocurrency yang volatile (Luo et al., 2025; Rashid & Ismail, 2023; Tan & Tao, 2023). Metrik ini dapat dikelompokkan dalam beberapa kategori:

1. Metrik Pasar:

- Market Cap: Total nilai market cryptocurrency
- Volume Perdagangan: Jumlah cryptocurrency yang diperdagangkan dalam periode tertentu
- Volatilitas: Tingkat fluktuasi harga dalam jangka waktu tertentu

2. Metrik Sosial (Bhatt et al., 2023; di Tollo et al., 2023):

- Jumlah Followers di Media Sosial (Twitter, Telegram, dll.)
- Tingkat aktivitas, pertumbuhan dan kontribusi komunitas terhadap proyek

Metrik popularitas dapat dimodelkan sebagai skor komposit menggunakan fungsi:

$$P_i = \alpha \cdot M_i + \beta \cdot S_i + \gamma \quad (7)$$

Di mana P_i merupakan skor popularitas untuk cryptocurrency ke- i , yang dihitung berdasarkan kombinasi dari metrik pasar M_i dan metrik sosial S_i , yang masing-masing telah dinormalisasi. Parameter α , β dan γ berfungsi sebagai bobot yang mengatur kontribusi relatif dari masing-masing metrik terhadap skor akhir popularitas.

Analisis tren investasi cryptocurrency melibatkan pelacakan perubahan pada metrik-metrik ini untuk mengidentifikasi momentum, reversals, atau pola pertumbuhan yang dapat mengindikasikan peluang investasi potensial.

Dalam sistem rekomendasi, metrik-metrik ini berperan sebagai fitur penting untuk meningkatkan akurasi rekomendasi, khususnya dalam pendekatan Feature-Enhanced CF yang memanfaatkan informasi kontekstual di luar pola interaksi pengguna.

2.1.7 Metrik Berbasis Relevansi

Metrik berbasis relevansi fokus pada seberapa relevan rekomendasi yang diberikan kepada pengguna:

1. Precision

Precision mengukur kualitas rekomendasi yang diberikan, dihitung sebagai rasio antara jumlah item yang relevan dalam daftar rekomendasi dibandingkan dengan seluruh item yang direkomendasikan. Mengadaptasi definisi yang dibahas oleh (Kumar et al., 2021, hal. 128) namun dengan penyesuaian untuk konteks cryptocurrency, formula precision yang digunakan dalam penelitian ini adalah:

$$Precision = \frac{|Relevant\ Items \cap Recommended\ Items|}{|Recommended\ Items|} \quad (8)$$

Precision menunjukkan seberapa tepat prediksi dibandingkan dengan penilaian sebenarnya dari pengguna. Metrik ini mengukur kemampuan

sistem untuk memberikan elemen yang relevan dengan jumlah rekomendasi minimal.

2. Recall

Recall mengukur kemampuan sistem untuk menemukan semua item yang relevan. Dihitung sebagai rasio antara jumlah item relevan yang muncul dalam daftar rekomendasi dibandingkan dengan seluruh item yang relevan. Mengadaptasi definisi yang dibahas oleh (Kumar et al., 2021, hal. 128), namun dengan penyesuaian untuk konteks cryptocurrency, formula recall yang digunakan dalam penelitian ini adalah:

$$Recall = \frac{|RelevantItems \cap RecommendedItems|}{|RelevantItems|} \quad (9)$$

Recall didefinisikan sebagai model untuk menemukan semua item yang serupa dan merekomendasikannya kepada pengguna

3. Normalized Discounted Cumulative Gain (NDCG)

Sebagaimana disebutkan oleh Bellogín dalam buku (Kumar et al., 2021), nDCG merupakan metrik berbasis peringkat yang memberikan bobot lebih besar pada item yang direkomendasikan pada posisi lebih tinggi dalam daftar rekomendasi. nDCG mengukur kualitas peringkat rekomendasi dengan mempertimbangkan posisi item yang relevan.

2.1.8 Perbandingan Model Rekomendasi

Tabel 2.1 Perbandingan Model Rekomendasi

Aspek	Neural Collaborative Filtering (NCF)	Feature-Enhanced Collaborative Filtering (FE CF)
Arsitektur	Deep learning dengan embedding dan multi-layer neural network (Kulkarni et al., 2023; Zhang et al., 2024)	Algoritma yang menggabungkan CF klasik dengan fitur item (Majumdar, 2024; W. Yang et al., 2022)
Kekuatan	Menangkap interaksi non-linear dan kompleks antara pengguna-item (Kulkarni et al., 2023; Mukherjee et al., 2024)	Interpretabilitas tinggi dan performa baik di lingkungan sparse (Majumdar, 2024; Zhang et al., 2024)
Kompleksitas	Tinggi (banyak parameter, membutuhkan data training besar) (Kulkarni et al., 2023)	Sedang (lebih sederhana dari NCF namun lebih kompleks dari CF biasa) (W. Yang et al., 2022)
Komputasi	Mebutuhkan waktu pelatihan lebih lama dan sumber daya komputasi lebih besar (Kulkarni et al., 2023)	Lebih efisien secara komputasi (W. Yang et al., 2022) dibandingkan NCF.
Cold-Start	Kurang efektif untuk cold-start problem karena ketergantungan pada data interaksi (Himeur et al., 2022)	Lebih baik dalam menangani cold-start berkat integrasi fitur tambahan (kategori, metadata) (Majumdar, 2024; W. Yang et al., 2022)
Kebutuhan Data	Mebutuhkan volume data interaksi yang cukup besar untuk pelatihan model (Kulkarni et al., 2023)	Dapat bekerja dengan data interaksi yang lebih terbatas dengan memanfaatkan fitur item (W. Yang et al., 2022)
Personalisasi	Sangat baik untuk personalisasi mendalam melalui pemodelan preferensi laten (Kulkarni et al., 2023; Mukherjee et al., 2024)	Baik untuk personalisasi berbasis kategori dan fitur eksplisit (Majumdar, 2024; W. Yang et al., 2022)

Implementasi hybrid model dalam domain aset digital blockchain telah menunjukkan efektivitas superior dibandingkan single-method approaches. Penelitian (Aydogdu & Aydin, 2024) pada sistem rekomendasi NFT membuktikan bahwa kombinasi Neural Collaborative Filtering dengan feature enhancement

menghasilkan peningkatan accuracy hingga 15-20% dibandingkan metode konvensional, khususnya dalam menangani extreme sparsity data yang karakteristik pada digital asset domains

2.1.9 Analisis Teknikal dalam Cryptocurrency

Analisis teknikal adalah metode evaluasi investasi yang meneliti pola pergerakan harga historis untuk memprediksi pergerakan harga masa depan. Metode ini mengasumsikan bahwa harga mencerminkan semua informasi yang tersedia dan bergerak dalam pola yang dapat diidentifikasi dan diinterpretasikan. Dalam konteks cryptocurrency, analisis teknikal menjadi pendekatan yang umum digunakan karena sifat pasar yang sangat volatil dan berbasis data historis.

Penelitian yang dilakukan oleh (Jung et al., 2023) mendemonstrasikan efektivitas penggunaan analisis teknikal dalam prediksi tren harga Bitcoin. Studi tersebut mengombinasikan 11 indikator teknikal termasuk Moving Average, Relative Strength Index (RSI), dan Stochastic Oscillator dengan analisis sentimen untuk meningkatkan akurasi prediksi tren pasar. Hasilnya menunjukkan bahwa indikator-indikator teknikal dapat memberikan sinyal yang signifikan terhadap pergerakan harga di pasar cryptocurrency.

Salah satu indikator yang banyak digunakan adalah Relative Strength Index (RSI), dihitung sebagai:

$$RSI = 100 - \frac{100}{1+RS} \quad (10)$$

Di mana RS adalah rasio dari rata-rata gain dibagi rata-rata loss selama periode tertentu:

$$RS = \frac{\text{Average Gain}}{\text{Average Loss}} \quad (11)$$

Periode indikator (jumlah interval waktu yang digunakan dalam perhitungan) merupakan parameter penting yang dapat disesuaikan untuk berbagai gaya trading: jangka pendek (periode lebih pendek), standar, dan jangka panjang.

Dalam konteks sistem rekomendasi cryptocurrency, sinyal dari analisis teknikal dapat diintegrasikan sebagai fitur tambahan dalam model rekomendasi, memberikan dimensi tambahan selain metrik popularitas dan tren sosial.

2.1.10 Cold-Start Problem dan Sparsitas dalam Sistem Rekomendasi

Cold-start problem adalah tantangan utama dalam sistem rekomendasi yang terjadi ketika sistem harus memberikan rekomendasi untuk pengguna baru (user cold-start) atau item baru (item cold-start) dengan sedikit atau tanpa data interaksi sebelumnya. Sebagian besar pengguna hanya berinteraksi dengan sebagian kecil dari seluruh item yang tersedia, mengakibatkan matriks rating yang sangat jarang (sparse). Hal ini dapat mengurangi efektivitas algoritma collaborative filtering karena keterbatasan data untuk menghitung kemiripan (Kumar et al., 2021; Majumdar, 2024).

Dalam konteks investasi cryptocurrency, masalah ini sangat relevan karena kemunculan proyek baru yang konstan dan banyaknya investor baru yang memasuki ekosistem.

Dalam formulasi matematika, masalah cold-start untuk user dan item dapat direpresentasikan sebagai kasus di mana jumlah interaksi yang diketahui sangat sedikit atau bahkan tidak memiliki riwayat interaksi, sehingga menyulitkan sistem rekomendasi untuk memberikan prediksi yang akurat.

$$\text{cold - start user } u : \sum_{i \in I} \mathbb{I}(r_{ui} \neq ?) \ll |I| \quad (12)$$

$$\text{cold - start user } i : \sum_{u \in U} \mathbb{I}(r_{ui} \neq ?) \ll |U| \quad (13)$$

Dimana $\mathbb{I}(\cdot)$ adalah fungsi indikator yang bernilai 1 jika kondisi di dalam tanda kurung terpenuhi dan 0 jika tidak, Simbol I merepresentasikan himpunan item yang tersedia dalam sistem rekomendasi, sedangkan U adalah himpunan seluruh pengguna.

Dalam konteks aset digital, cold-start problem memiliki kompleksitas tambahan karena nature dari blockchain assets yang memiliki lifecycle pendek dan high volatility. Penelitian (Aydogdu & Aydin, 2024) mengidentifikasi bahwa three-phase bootstrapping approach (content-based initialization, popularity-based fallback, dan cross-domain transfer) efektif mengatasi cold-start problem pada domain aset digital dengan success rate 60-70% untuk new users dan new items.

Beberapa strategi untuk mengatasi cold-start problem meliputi pendekatan berbasis konten, model hybrid, active learning, metode berbasis pengetahuan, dan rekomendasi berbasis minat (Kulkarni et al., 2023). Feature-Enhanced CF dan Hybrid dari gabungan (FECF dan NCF) dengan integrasi fitur kontekstual dapat mengurangi dampak cold-start problem dengan memanfaatkan informasi seperti

kategori proyek, chain, dan metrik popularitas untuk membuat rekomendasi yang lebih relevan bahkan dengan data interaksi yang terbatas.

2.1.11 Software dan Pemrograman Terkait

2.1.11.1 Python untuk Data Science dan Machine Learning

Python telah menjadi bahasa pemrograman pilihan untuk pengembangan sistem rekomendasi dan aplikasi machine learning karena sintaksnya yang mudah dibaca, kemampuan prototyping yang cepat, dan ekosistem library yang kaya (Kulkarni et al., 2023). Dalam konteks pengembangan sistem rekomendasi cryptocurrency, Python menyediakan berbagai tools:

- NumPy dan Pandas: Untuk manipulasi dan analisis data
- Scikit-learn: Untuk implementasi algoritma machine learning dasar dan evaluasi model
- PyTorch dan TensorFlow: Untuk pengembangan model neural network kompleks dan analisis pergerakan pasar

2.1.11.2 Scikit-learn

Scikit-learn adalah library machine learning open-source untuk Python yang menyediakan implementasi efisien dari berbagai algoritma machine learning, termasuk beberapa yang relevan untuk sistem rekomendasi:

- Matrix Factorization: Implementasi SVD (Singular Value Decomposition) untuk collaborative filtering
- Clustering Algorithms: K-Means untuk segmentasi pengguna atau item

- Preprocessing Tools: Untuk normalisasi fitur dan penanganan missing values
- Model Evaluation: Metrics dan cross-validation untuk evaluasi performa sistem rekomendasi

Implementasi SVD untuk matrix factorization dalam scikit-learn memecahkan matriks pengguna-item R menjadi tiga matriks:

$$R \approx U\Sigma V^T \quad (14)$$

Dimana U dan V adalah matriks ortogonal yang berisi vektor singular kiri dan kanan, dan Σ adalah matriks diagonal dengan nilai singular.

2.1.11.3 PyTorch

PyTorch adalah framework deep learning yang menawarkan fleksibilitas tinggi dalam pengembangan model neural network kompleks seperti Neural Collaborative Filtering (Omar et al., 2024). Kelebihan PyTorch meliputi:

- Dynamic Computational Graphs: Memungkinkan debugging yang lebih mudah
- Intuitive API: Mirip dengan programming Python standar
- Optimizers: Implementasi berbagai algoritma optimasi seperti Adam, SGD dengan momentum
- GPU Acceleration: Dukungan native untuk komputasi paralel di GPU

Model NCF dalam PyTorch dapat diimplementasikan dengan multiple layers dan aktivasi non-linear:

$$\hat{y}_{ui} = \sigma(W_L \cdot \sigma(W_{L-1} \cdot \dots \sigma(W_1 \cdot [p_u, q_i]) \dots)) \quad (15)$$

Dimana σ adalah fungsi aktivasi non-linear seperti ReLU, W_l adalah matriks bobot layer l dan $[p_u, q_i]$ adalah konkatenasi dari embedding pengguna dan item.

2.1.11.4 Laravel Framework

Laravel adalah framework PHP yang menyediakan syntax yang elegan dan fitur-fitur yang mempercepat pengembangan web modern (Sinlae et al., 2024).

Dalam konteks sistem rekomendasi cryptocurrency, Laravel berperan sebagai:

- Backend Infrastructure: Menangani autentikasi, database, dan business logic
- API Integration: Menghubungkan frontend dengan engine rekomendasi Python
- Data Caching: Meningkatkan performa melalui caching hasil rekomendasi
- MVC Architecture: Organisasi kode yang terstruktur untuk maintainability yang lebih baik

2.1.12 Aplikasi Sistem Rekomendasi pada Domain Blockchain

Domain blockchain dan aset digital memperkenalkan tantangan unik untuk sistem rekomendasi yang tidak ditemukan pada domain tradisional. Karakteristik khusus meliputi extreme data sparsity, rapid asset lifecycle, dan availability of on-chain transaction data sebagai additional feature source (Aydogdu & Aydin, 2024).

Penelitian dalam NFT recommendation systems menunjukkan bahwa traditional collaborative filtering approaches mengalami significant performance degradation ketika diterapkan pada blockchain assets due to unique characteristics seperti immutability, proof of ownership, dan cross-platform dependencies. Hybrid approaches yang mengintegrasikan collaborative filtering dengan blockchain analytics telah terbukti mengatasi limitations ini dengan effectiveness rate yang significantly higher dibandingkan conventional methods (Aydogdu & Aydin, 2024).

Integration of on-chain data sebagai contextual features dalam recommendation algorithms memungkinkan systems untuk capture user behavior patterns yang tidak visible melalui traditional interaction data alone. Hal ini particularly relevant untuk cryptocurrency domain di mana transaction patterns, wallet behaviors, dan cross-chain activities memberikan rich contextual information untuk improving recommendation accuracy dan relevance.

2.2 Tinjauan Literatur/Kajian Penelitian Terdahulu

2.2.1 Paper 1: "Enhancing Neural Collaborative Filtering Using Hybrid Feature Selection for Recommendation" (Drammeh & Li, 2023, PeerJ Computer Science, Q2)

2.2.1.1 Tujuan Penelitian

Penelitian ini bertujuan untuk mengembangkan sistem rekomendasi berbasis collaborative filtering yang ditingkatkan dengan pendekatan convolutional neural network (CNN), outer product matrix, dan modul hybrid feature selection

untuk menangkap interaksi tingkat tinggi baik secara lokal maupun global antara pengguna dan item.

2.2.1.2 Metodologi Yang Digunakan

Metodologi yang digunakan adalah pengembangan model deep collaborative recommendation system yang mengkombinasikan:

- Convolutional neural network (CNN)
- Outer product matrix untuk representasi interaksi pengguna-item
- Modul hybrid feature selection untuk menangkap pola lokal dan global
- Integrasi dengan bobot generalized matrix factorization (GMF)

Model diuji menggunakan dua dataset dunia nyata dengan tingkat sparsity yang berbeda (MovieLens dan Pinterest) dan dievaluasi dengan metrik performa rekomendasi standar.

2.2.1.3 Temuan Utama

Penelitian ini menemukan bahwa:

- Pendekatan hybrid yang diusulkan secara signifikan mengungguli metode-metode baseline
- Stacked interaction map berhasil meningkatkan ekspresivitas fitur input dan memungkinkan peta interaksi untuk mengkode lebih banyak sinyal laten
- Modul hybrid feature selection efektif dalam menangkap korelasi antara item

- Integrasi dengan GMF membantu mengoptimalkan performa jaringan dan mencegah overfitting

2.2.1.4 Kesimpulan Penelitian

Penelitian menyimpulkan bahwa pendekatan hybrid yang menggabungkan CNN, outer product, dan hybrid feature selection terbukti efektif dalam meningkatkan performa sistem rekomendasi. Pendekatan ini memungkinkan pemrosesan informasi yang lebih komprehensif dari data interaksi pengguna-item dan berhasil menangkap pola-pola kompleks yang sulit ditangkap oleh metode tradisional.

2.2.2 Paper 2: "Enhancing Neural Collaborative Filtering with Metadata for Book Recommender System" (Mukti & Baizal, 2025, IJCCS, Sinta 2)

2.2.2.1 Tujuan Penelitian

Penelitian ini bertujuan untuk mengatasi masalah information overload dan item cold start pada sistem rekomendasi buku dengan mengusulkan model Feature Enhanced Neural Collaborative Filtering (FENCF) yang menggabungkan interaksi pengguna-item dengan informasi metadata genre untuk meningkatkan akurasi prediksi rating.

2.2.2.2 Metodologi Yang Digunakan

Metodologi yang digunakan meliputi:

- Pengembangan model FENCF yang memodifikasi Neural Collaborative Filtering

- Praproses metadata genre menggunakan Sentence BERT dan K-means untuk pengelompokan genre
- Pemodelan dengan kombinasi Generalized Matrix Factorization (GMF) dan Multi-Layer Perceptron (MLP)
- Evaluasi menggunakan dataset buku Amazon dengan metrik RMSE dan MAE
- Perbandingan dengan metode baseline seperti NCF standar

2.2.2.3 Temuan Utama

Hasil penelitian menunjukkan bahwa:

- FENCF berhasil mengungguli NCF dengan mengurangi RMSE sebesar 4,04% dan MAE sebesar 2,73%
- FENCF lebih mampu mengatasi masalah item cold start dengan MAE yang lebih rendah di semua skenario pengujian
- Penggunaan metadata genre yang diproses dengan Sentence BERT dan K-means terbukti efektif untuk meningkatkan akurasi rekomendasi
- Model dapat merekomendasikan buku baru dengan lebih akurat meskipun memiliki data rating yang terbatas

2.2.2.4 Kesimpulan Penelitian

Penelitian menyimpulkan bahwa FENCF mampu secara signifikan meningkatkan akurasi prediksi rating dan mengatasi masalah item cold start pada sistem rekomendasi buku. Pendekatan ini sangat relevan untuk kondisi aktual

penjualan buku di e-commerce yang bersifat dinamis, dan berpotensi meningkatkan pengalaman pengguna serta tingkat konversi penjualan.

2.2.3 Paper 3: "Feature-enhanced Embedding Learning for Heterogeneous Collaborative Filtering" (W. Yang et al., 2022, Neural Computing and Applications, Q1)

2.2.3.1 Tujuan Penelitian

Penelitian ini bertujuan untuk mengembangkan model rekomendasi berbasis Heterogeneous Information Network (HIN) yang menggabungkan strategi inisialisasi fitur informatif dengan arsitektur pembelajaran yang sederhana untuk collaborative filtering heterogen, dengan fokus pada pengkodean fitur daripada arsitektur pembelajaran yang kompleks.

2.2.3.2 Metodologi Yang Digunakan

Metodologi yang diusulkan meliputi:

- Pengembangan Feature-enhanced Heterogeneous Collaborative Filtering (FHetCF)
- Dekomposisi HIN menjadi jaringan homogen menggunakan meta-path
- Strategi inisialisasi fitur menggunakan pengkodean semantik dan spasial
- Arsitektur pembelajaran berbasis multi-layer perceptron (MLP)
- Mekanisme fusi berbasis convolutional neural network (1D-CNN) untuk menentukan bobot perhatian pada relasi semantik

- Evaluasi pada dataset Yelp dan Amazon dengan metrik Hit Ratio dan NDCG

2.2.3.3 Temuan Utama

Hasil eksperimen menunjukkan bahwa:

- FHetCF secara signifikan mengungguli model-model baseline dengan peningkatan 1,71-10,46% pada Hit Ratio dan 3,17-13,75% pada NDCG
- Strategi inisialisasi fitur yang komprehensif lebih efektif daripada inisialisasi acak atau berbasis meta-path sederhana
- 1D-CNN berbasis mekanisme fusi efektif dalam menentukan kepentingan relasi semantik yang berbeda
- Kombinasi inisialisasi fitur informatif dengan arsitektur pembelajaran sederhana mampu mencapai performa rekomendasi yang memuaskan

2.2.3.4 Kesimpulan Penelitian

Penelitian menyimpulkan bahwa perancangan sistem rekomendasi heterogen yang efektif tidak selalu membutuhkan arsitektur pembelajaran yang kompleks. FHetCF dengan fokus pada strategi inisialisasi fitur yang informatif terbukti dapat menghasilkan performa rekomendasi yang unggul. Pendekatan ini membuka jalan baru untuk memanfaatkan informasi heterogen secara efektif untuk meningkatkan performa rekomendasi.

2.2.4 Paper 4: “Development of a Hybrid Recommendation System for NFTs Using Deep Learning Techniques” (Aydogdu & Aydin, 2024, IEEE Access, Q1)

2.2.4.1 Tujuan Penelitian

Penelitian ini bertujuan untuk mengembangkan sistem rekomendasi NFT yang personal dan efektif dengan memanfaatkan metode deep learning, terutama gabungan antara Neural Collaborative Filtering (NCF) dan AutoEncoder (AE). Tujuannya adalah untuk mengatasi tantangan seperti data sparsity, tidak adanya data demografis, serta keterbatasan feedback eksplisit dalam domain NFT.

2.2.4.2 Metodologi Yang Digunakan

Penelitian ini mengusulkan model hybrid bernama NFT-NCFAE, yang menggabungkan komponen NCF untuk menangkap interaksi user-item dan AutoEncoder untuk mengekstrak fitur penting dari data pengguna dan NFT (gambar, teks, harga, dan histori transaksi). Evaluasi model dilakukan menggunakan metrik Recall@k dan NDCG@k, dengan pendekatan perbandingan terhadap model sebelumnya (NFT-MARS) menggunakan dataset NFT publik.

2.2.4.3 Temuan Utama

Hasil penelitian menunjukkan bahwa model NFT-NCFAE memberikan performa yang unggul dibandingkan model sebelumnya, termasuk dalam hal akurasi rekomendasi dan efisiensi komputasi. Model ini berhasil mengatasi cold-start problem dan memberikan hasil yang lebih baik terutama dalam koleksi NFT dengan interaksi terbatas, seperti Doodles.

2.2.4.4 Kesimpulan Penelitian

Penelitian ini menyimpulkan bahwa pendekatan hybrid deep learning dengan menggabungkan NCF dan AE mampu meningkatkan akurasi serta efisiensi sistem rekomendasi NFT secara signifikan. Integrasi fitur NFT yang kaya seperti gambar, teks, harga, dan histori transaksi terbukti memberikan dampak positif terhadap kualitas rekomendasi. Model ini juga memberikan fondasi yang kuat untuk pengembangan sistem rekomendasi NFT yang lebih canggih dan dapat diskalakan di masa depan.

2.2.5 Paper 5: “Improved recommender system using Neural Network Collaborative Filtering (NNCF) for E-commerce cosmetic product” (Subhan et al., 2025, Sinergi (Indonesia), Sinta 2)

2.2.5.1 Tujuan Penelitian

Penelitian ini bertujuan untuk mengembangkan sistem rekomendasi yang ditingkatkan untuk platform e-commerce yang mengkhususkan diri pada produk kosmetik. Masalah utama yang diidentifikasi adalah sistem rekomendasi tradisional sering mengalami kesulitan memberikan rekomendasi yang akurat dan dipersonalisasi karena kompleksitas dan subjektivitas yang melekat dalam preferensi kosmetik.

2.2.5.2 Metodologi Yang Digunakan

Penelitian ini menerapkan pendekatan Neural Network Collaborative Filtering (NNCF) dengan langkah preprocessing yang ditingkatkan. Metodologi meliputi:

- Preprocessing data - menangani nilai yang hilang dan melakukan reduksi data
- Pemodelan NNCF - mengintegrasikan jaringan neural ke dalam filtering kolaboratif
- Evaluasi model menggunakan metrik Mean Reciprocal Ratings (MRR) dan Normalized Discount Cumulative Gain (NDCG)

Dataset yang digunakan adalah "eCommerce Event History in Cosmetics Shop" dari Kaggle, yang berisi 8,738,120 baris data interaksi pengguna-produk. Data dibagi dengan rasio 70% data training, 15% data validasi, dan 15% data testing.

2.2.5.3 Temuan Utama

Hasil penelitian menunjukkan:

- Metrik evaluasi MRR dan NDCG mencapai nilai 0,56 dan 0,60
- Hasil ini jauh lebih baik dibandingkan penelitian sebelumnya yang memiliki MRR 0,31 dan NDCG 0,32
- Model NNCF dengan reduksi data menunjukkan ketahanan terhadap masalah data yang jarang (sparsity) dan cold-start
- Pendekatan preprocessing yang dioptimalkan berperan penting dalam meningkatkan performa model

2.2.5.4 Kesimpulan Penelitian

Penelitian ini berhasil mengembangkan sistem rekomendasi yang lebih efektif untuk produk kosmetik e-commerce. Model yang diusulkan tidak hanya

mengatasi tantangan dalam rekomendasi kosmetik tetapi juga memberikan pemahaman yang lebih baik tentang bagaimana preprocessing data dapat meningkatkan kinerja sistem rekomendasi. Penelitian ini membuka jalan untuk pengalaman berbelanja online yang lebih dipersonalisasi dan efisien.

