

BAB I

Pendahuluan

Latar Belakang

Industri *video game* telah mengalami pertumbuhan pesat dan menjadi salah satu sektor teknologi informasi yang paling cepat berkembang. Pada tahun 2019, pendapatan global dari pasar *video game* mencapai \$152 miliar, meningkat sebesar 9,6% dibandingkan tahun sebelumnya [1]. Pertumbuhan ini didorong oleh bertambah banyaknya platform yang menawarkan berbagai judul *game* dan fitur yang meningkatkan pengalaman bermain. Di antara platform-platform tersebut, Steam menonjol sebagai layanan distribusi digital terkemuka, memungkinkan pengguna untuk membeli, melihat, dan memainkan *video game* secara online maupun offline [2]. Fitur-fitur yang luas dan kehadiran pasar yang kuat menjadikan Steam pilihan utama bagi *gamer* di seluruh dunia.

Namun, dengan meningkatnya jumlah pengguna dan produk yang ditawarkan, semakin sulit bagi pengguna untuk menemukan *game* baru yang sesuai dengan minat mereka. Data dari Steam pada tahun 2014 menunjukkan bahwa 37% dari *game* yang dibeli oleh pengguna tidak pernah dimainkan, dan 17% dari *game* yang dibeli hanya dimainkan kurang dari satu jam [2]. Data ini menunjukkan bahwa sebagian besar pengguna Steam merasa bahwa *game* yang mereka beli tidak memenuhi ekspektasi mereka. Oleh karena itu, perlu dikembangkan sistem rekomendasi yang dapat membantu pengguna menemukan *game* yang sesuai dengan preferensi dan minat mereka

Topik dan Batasannya

Penelitian ini berfokus pada pengembangan sistem rekomendasi *video game* menggunakan pendekatan *Deep Learning Collaborative Recommender System (DLCRS)* [3]. Topik utama penelitian ini adalah penerapan DLCRS, yang mengintegrasikan teknik *deep learning* dengan metode *Collaborative Filtering*, untuk mengatasi tantangan dalam merekomendasikan *game* dari katalog yang sangat luas di platform Steam. Dengan banyaknya pilihan *game* yang tersedia, tantangan utama yang dihadapi adalah data *sparsity* dan *cold start* yang sering menghambat akurasi rekomendasi dalam sistem konvensional.

Data sparsity merujuk pada situasi di mana data interaksi antara pengguna dan item (dalam hal ini, *game*) tidak cukup memadai untuk membangun profil pengguna yang akurat, sehingga mengakibatkan rekomendasi yang tidak tepat [4]. *Cold start* adalah masalah ketika sistem rekomendasi harus memberikan rekomendasi untuk item baru atau pengguna baru yang belum memiliki cukup data interaksi, sehingga sulit bagi sistem untuk memberikan rekomendasi yang relevan [4].

Dalam penelitian ini, dataset yang digunakan mencakup ulasan *game* dan data waktu bermain dari pengguna Steam di Australia. Data ini diproses untuk menghasilkan rating biner menggunakan DistilBERT [5] dan kemudian diproses lebih lanjut dengan teknik *negative sampling*. Keluaran dari algoritma adalah rekomendasi *game* yang relevan dan akurat untuk pengguna Steam, dengan performa yang dievaluasi menggunakan metrik AUC, *Precision*, *Recall*, dan F1-Score.

Sebagai contoh, seorang pengguna baru di Steam yang belum memiliki banyak interaksi dengan *game* akan menghadapi kesulitan dalam mendapatkan rekomendasi yang relevan karena data interaksinya yang terbatas. Penelitian ini bertujuan untuk mengevaluasi apakah DLCRS dapat memberikan rekomendasi yang lebih efektif dibandingkan metode konvensional dalam situasi seperti ini.

Beberapa batasan diterapkan dalam penelitian ini. Pertama, dataset yang digunakan hanya mencakup ulasan dan data waktu bermain dari pengguna Steam di Australia. Batasan ini disebabkan oleh keterbatasan akses data dan waktu yang tersedia untuk penelitian, sehingga hasilnya mungkin tidak sepenuhnya mencerminkan preferensi pengguna global. Kedua, penelitian ini berfokus pada penerapan DLCRS dan perbandingannya dengan metode *Neural Collaborative Filtering (NCF)*, *Neural Factorization Machines (NFM)*, dan *Deep Learning Recommendation Model (DLRM)*. NFM, yang menggabungkan *factorization machine* dengan *neural network*, memberikan perbandingan terkait kemampuan menangkap interaksi *non-linear* antara fitur pengguna dan item [6]. NCF, dengan fokus pada penggunaan *neural network* untuk *Collaborative Filtering*, menawarkan dasar evaluasi terhadap pendekatan *end-to-end* dalam merepresentasikan interaksi pengguna-item [7]. Sementara itu, DLRM, sebagai model *deep learning* terkemuka yang mengintegrasikan *embedding* dan *multi-layer perceptron*, menyediakan *benchmark* kuat untuk perbandingan dengan model *deep learning* yang canggih [8]. Ketiga model ini telah terbukti efektif dalam literatur, sehingga memberikan landasan yang solid untuk menilai seberapa baik DLCRS dalam mengatasi tantangan *data sparsity* dan *cold start* dalam sistem rekomendasi *video game* di platform Steam. Penelitian ini tidak mencakup eksplorasi model-model rekomendasi lainnya yang mungkin juga memiliki potensi untuk meningkatkan performa sistem rekomendasi. Batasan-batasan ini diadopsi untuk menyederhanakan permasalahan dan menjaga fokus penelitian agar dapat diselesaikan secara efektif dalam kerangka waktu dan sumber daya yang tersedia.

Tujuan

Penelitian ini bertujuan untuk mengembangkan sistem rekomendasi *video game* yang efektif untuk platform Steam dengan menggunakan model *Deep Learning Collaborative Recommender System (DLCRS)*. Penelitian ini

akan mengkaji bagaimana DLCRS dapat meningkatkan akurasi dan relevansi rekomendasi *video game* dibandingkan dengan pendekatan lain dalam rekomendasi, yaitu *Neural Collaborative Filtering* (NCF), *Neural Factorization Machines* (NFM), dan *Deep Learning Recommendation Model* (DLRM).

Secara khusus, penelitian ini akan mengejar tiga tujuan utama. Pertama, penelitian ini akan mengembangkan sistem rekomendasi yang memanfaatkan DLCRS untuk membantu pengguna Steam menemukan *game* yang sesuai dengan preferensi mereka. Kedua, penelitian ini akan membandingkan performa DLCRS dengan model-model lain, yaitu NCF, NFM, dan DLRM, dengan menggunakan metrik evaluasi seperti AUC, *Precision*, *Recall*, dan F1-Score untuk menilai akurasi dan relevansi rekomendasi. Ketiga, penelitian ini akan mengevaluasi efektivitas DLCRS dalam mengatasi masalah *sparsity* data dan kompleksitas interaksi pengguna-item, serta menentukan keunggulan model ini dibandingkan dengan model-model lainnya.

Melalui pencapaian tujuan-tujuan ini, penelitian ini berharap dapat memberikan kontribusi yang berarti dalam pengembangan sistem rekomendasi *video game* yang lebih akurat dan relevan, serta memberikan wawasan mengenai kinerja berbagai model dalam konteks rekomendasi *video game*.

Organisasi Tulisan

Penelitian ini akan dijelaskan dalam beberapa bagian yaitu: Studi Terkait yang menjelaskan mengenai penelitian sebelumnya mengenai topik penelitian ini; Sistem yang Dibangun yang menjelaskan mengenai struktur dan cara kerja sistem yang dibangun dalam penelitian ini; Evaluasi yang membahas hasil eksperimen pada penelitian ini; dan Kesimpulan yang memberikan ringkasan dari hasil penelitian.