

BAB 1 PENDAHULUAN

1.1. Latar Belakang

Sistem rekomendasi (recommender system) merupakan bagian penting dalam teknologi digital yang mendukung pengalaman pengguna di berbagai platform, seperti layanan streaming musik, video, e-commerce, dan media sosial. Di Spotify, sistem ini berperan dalam menyarankan lagu-lagu yang sesuai dengan selera pengguna berdasarkan interaksi atau riwayat mendengarkan sebelumnya [6]. Seiring meningkatnya volume data dan kompleksitas preferensi pengguna, pendekatan sistem rekomendasi yang tradisional seperti collaborative filtering, semakin menunjukkan keterbatasannya. Sistem-sistem tersebut sering kali tidak mempertimbangkan konteks urutan interaksi pengguna, padahal dalam dunia musik, urutan lagu dalam sebuah playlist dapat mencerminkan preferensi tematik atau emosional yang penting [11]. Preferensi tematik mengacu pada kesesuaian tema, seperti romantis, semangat, atau melankolis, yang membentuk karakter keseluruhan playlist. Selain itu, urutan song_id dalam playlist juga merepresentasikan perilaku pengguna (user behaviour) berupa kecenderungan pengguna terhadap jenis atau karakteristik lagu tertentu, yang perlu dipelajari untuk menghasilkan prediksi yang lebih akurat.

Untuk menjawab tantangan tersebut, penelitian ini mengusulkan pendekatan berbasis sequence prediction yang lebih adaptif dan kontekstual, dengan menggabungkan tiga komponen utama, yaitu Gated Recurrent Unit (GRU), attention mechanism, dan item embeddings. GRU dipilih karena kemampuannya dalam mempelajari pola urutan data secara efisien, terutama pada data sekuensial seperti playlist lagu. Berbeda dengan arsitektur RNN konvensional, GRU memiliki struktur yang lebih sederhana dan lebih efektif dalam menangkap dinamika interaksi jangka pendek maupun panjang [7].

Selanjutnya, attention mechanism ditambahkan untuk meningkatkan kemampuan model dalam menyoroti elemen-elemen penting dalam urutan lagu. Alih-alih memperlakukan semua lagu sebelumnya dengan bobot yang sama, mekanisme ini memungkinkan model untuk memfokuskan

perhatian pada lagu-lagu yang paling relevan terhadap prediksi, sehingga hasil rekomendasi menjadi lebih tepat sasaran [8].

Komponen ketiga, yaitu item embeddings, digunakan untuk merepresentasikan setiap lagu dalam bentuk vektor berdimensi rendah yang memuat informasi semantik (seperti makna atau karakteristik lagu) dan kemiripan antar lagu. Embeddings ini memungkinkan model mengenali pola laten, yaitu hubungan tersembunyi yang tidak langsung terlihat, dan membuat prediksi yang lebih fleksibel dibandingkan representasi one-hot yang kaku dan spars (jarang terisi) [9].

Pendekatan ini sekaligus bertujuan untuk menghasilkan sistem rekomendasi yang bersifat personal dan kontekstual. Sistem yang personal berarti mampu menyesuaikan rekomendasi dengan karakteristik unik masing-masing pengguna, berdasarkan riwayat interaksi dan pola preferensi individual. Sementara itu, sistem yang kontekstual mempertimbangkan informasi urutan dan hubungan antar lagu sebagai perilaku pengguna dan suatu kesatuan urutan dalam playlist, sehingga dapat memberikan rekomendasi yang lebih relevan dengan kondisi saat itu.

Dengan menggabungkan ketiga komponen tersebut, penelitian ini bertujuan membangun model rekomendasi lagu berikutnya (next-item recommender system) yang mampu memahami urutan interaksi pengguna secara lebih cerdas dan personal. Inovasi ini diharapkan dapat mengatasi keterbatasan sistem rekomendasi sebelumnya serta memberikan kontribusi terhadap pengembangan model-model rekomendasi modern yang lebih kontekstual, responsif, dan akurat dalam memahami preferensi musik pengguna.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang ada, rumusan masalah yang akan dijawab dalam penelitian ini adalah sebagai berikut:

1. Bagaimana performa model rekomendasi Next-Item berbasis kombinasi GRU, attention mechanism, dan item embeddings dalam memprediksi lagu berikutnya?
2. Seberapa besar kontribusi masing-masing komponen (GRU, attention, item embeddings) terhadap performa model secara keseluruhan?
3. Bagaimana perbandingan performa model pada evaluasi dengan berbagai nilai K dalam metrik Hit@K?

1.3. Tujuan dan Manfaat

1.3.1. Tujuan Penelitian

Penelitian ini bertujuan untuk:

1. Mengembangkan model sistem rekomendasi Next-Item berbasis sekuens dengan memanfaatkan arsitektur GRU, attention mechanism, dan item embeddings.
2. Mengevaluasi kontribusi masing-masing komponen model melalui eksperimen dan ablation study.
3. Menilai kinerja model dengan pendekatan evaluasi multi-K menggunakan metrik Hit@K.

1.3.2. Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat sebagai berikut:

1. Bagi akademisi, sebagai kontribusi ilmiah dalam bidang sistem rekomendasi berbasis deep learning, khususnya dalam pengolahan data sekuensial.
2. Bagi praktisi dan industri, sebagai alternatif pendekatan untuk mengembangkan sistem rekomendasi yang lebih akurat dan adaptif.
3. Bagi pengembang teknologi, sebagai referensi untuk mengimplementasikan dan mengevaluasi model rekomendasi sekuensial di domain musik atau konten serupa.

1.4. Batasan Masalah

Penelitian ini memiliki batasan sebagai berikut:

1. Dataset yang digunakan terbatas pada Spotify Playlist Dataset dari Kaggle, yang berisi urutan lagu-lagu dalam playlist pengguna.
2. Fokus model hanya pada prediksi lagu berikutnya (Next-Item) tanpa mempertimbangkan informasi pengguna secara eksplisit.
3. Eksperimen dilakukan dalam lingkungan Google Colab dengan sumber daya terbatas, sehingga skala data dan kompleksitas model disesuaikan.
4. Evaluasi model dibatasi pada metrik Hit@K untuk $K = 5, 10$, dan 15 .

1.5. Metode Penelitian

Metode yang digunakan dalam penelitian ini meliputi beberapa tahapan sebagai berikut:

1. **Studi Literatur:** Mengkaji referensi terkait sistem rekomendasi berbasis deep learning, khususnya model-model yang menggunakan GRU, attention mechanism, dan item embeddings.
2. **Pengumpulan dan Pra-pemrosesan Data:** Mengambil data dari Spotify Playlist Dataset (Kaggle), melakukan pembersihan data, encoding item, dan membentuk sekuens playlist sebagai input model.
3. **Perancangan Model:** Mendesain arsitektur model utama yang menggabungkan GRU, attention mechanism, dan item embeddings, serta merancang dua model baseline sebagai pembanding (yaitu GRU-only dan model dengan ukuran embedding berbeda). Baseline di sini merujuk pada model acuan awal yang digunakan untuk menilai sejauh mana peningkatan performa dari model utama.
4. **Eksperimen dan Pelatihan Model:** Melatih semua varian model selama 20 epoch pada lingkungan Google Colab menggunakan GPU, dan mencatat metrik evaluasi selama proses pelatihan.
5. **Evaluasi dan Analisis Hasil:** Mengevaluasi performa model dengan metrik Hit@K untuk berbagai nilai K, melakukan visualisasi, dan membandingkan hasil antar model melalui ablation study.
6. **Penyusunan Laporan Penelitian:** Menyusun hasil penelitian dalam bentuk laporan ilmiah dan menarik kesimpulan berdasarkan hasil eksperimen.

1.6. Jadwal Pelaksanaan

Untuk memastikan penelitian berjalan secara terstruktur dan sesuai dengan waktu yang direncanakan, berikut disusun jadwal kegiatan penelitian dalam bentuk tabel. Jadwal ini mencakup seluruh tahapan mulai dari penentuan topik hingga penyusunan laporan akhir:

Tabel 1.1. Jadwal Kegiatan

Kegiatan	Bulan					
	1	2	3	4	5	6

Penentuan Topik						
Studi Literatur						
Membuat Latar Belakang						
Membuat Perancangan Sistem						
Implementasi						
Analisis Hasil Implementasi						
Penyusunan Laporan Akhir						