

**SISTEM REKOMENDASI FILM MULTI-KRITERIA
BERBASIS ALGORITMA *GREEDY* DENGAN
*DIVERSITY PENALTY***

SKRIPSI

**OLEH
SITI MA'RIFATUL MUSA'ADAH
NIM. 220601110028**



**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2026**

**SISTEM REKOMENDASI FILM MULTI-KRITERIA
BERBASIS ALGORITMA *GREEDY* DENGAN
*DIVERSITY PENALTY***

SKRIPSI

**Diajukan Kepada
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Matematika (S.Mat)**

**Oleh
Siti Ma'rifatul Musa'adah
NIM. 220601110028**

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2026**

**SISTEM REKOMENDASI FILM MULTI-KRITERIA
BERBASIS ALGORITMA *GREEDY* DENGAN
*DIVERSITY PENALTY***

SKRIPSI

Oleh
Siti Ma'rifatul Musa'adah
NIM. 220601110028

Telah Disetujui Untuk Diuji

Malang, 11 Mei 2026

Dosen Pembimbing I

Dosen Pembimbing II



Mohammad Nafie Jauhari, M.Si.
NIPPPK. 19870218 202321 1 018



Dr. Mohammad Jamhuri, M.Si.
NIP. 19810502 200501 1 004

Mengetahui,
Ketua Program Studi Matematika



Dr. Fachrudin Rozi, M.Si.
NIP. 19800527 200801 1 012

**SISTEM REKOMENDASI FILM MULTI-KRITERIA
BERBASIS ALGORITMA *GREEDY* DENGAN
*DIVERSITY PENALTY***

SKRIPSI

Oleh
Siti Ma'rifatul Musa'adah
NIM. 220601110028

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Sarjana Matematika (S.Mat)

Tanggal, 02 Juni 2026

Ketua Penguji : Hisyam Fahmi, M.Kom.

Anggota Penguji 1 : Muhammad Khudzaifah, M.Si.

Anggota Penguji 2 : Mohammad Nafie Jauhari, M.Si.

Anggota Penguji 3 : Dr. Mohammad Jamhuri, M.Si


.....

.....

Mengetahui,
Ketua Program Studi Matematika


Dr. Fachrud Rozi, M.Si.
NIP. 19800527 200801 1 012

PERNYATAAN KEASLIAN TULISAN

Saya bertanda tangan di bawah ini

Nama : Siti Ma'rifatul Musa'adah
NIM : 220601110028
Program Studi : Matematika
Fakultas : Sains dan Teknologi
Judul Skripsi : Sistem Rekomendasi Film Multi-kriteria Berbasis Algoritma
Greedy dengan Diversity Penalty

Menyatakan bahwa skripsi yang saya tulis ini merupakan hasil karya sendiri, bukan mengambil alih tulisan atau pemikiran orang lain. Saya menyatakan skripsi ini sebagai pemikiran saya, kecuali dengan mencantumkan sumber kutipan pada daftar rujukan di halaman terakhir. Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini hasil plagiasi atau tiruan orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 02 Juni 2026



Siti Ma'rifatul Musa'adah

NIM. 220601110028

MOTO

“Jika hidup membawamu sampai sejauh ini, berarti kamu cukup kuat untuk melangkah lebih jauh lagi.”

PERSEMBAHAN

Dengan penuh rasa syukur kepada Allah SWT. yang senantiasa memberikan kemudahan dalam segala hal, khususnya dalam penyelesaian skripsi ini. Skripsi ini penulis persembahkan kepada:

Kedua orang tua penulis, rumah pertama tempat penulis pulang setelah lelah menghadapi banyak hal. Terima kasih atas doa yang tidak pernah terputus, atas setiap usaha yang diam-diam disembunyikan agar penulis tetap bisa melangkah sejauh ini. Jika hari ini penulis berhasil sampai pada titik ini, itu karena kalian tidak pernah berhenti percaya, bahkan ketika penulis meragukan diri sendiri. Saudara dan keluarga besar penulis, terima kasih atas doa dan dukungan yang terus diberikan selama proses perjalanan ini.

Seseorang yang hingga hari ini masih membersamai penulis, terima kasih karena selalu menjadi tempat untuk pulang, didengar, dan dikuatkan tanpa banyak diminta.

Sahabat-sahabat penulis, terima kasih telah tumbuh dan berjuang bersama. Terima kasih untuk setiap dukungan, tawa, bantuan, dan kebersamaan yang membuat hari-hari sulit terasa lebih ringan.

KATA PENGANTAR

Puji syukur kehadiran Allah SWT. atas segala limpahan rahmat, taufik, dan hidayah-Nya sehingga skripsi ini dapat diselesaikan dengan lancar. Shalawat dan salam tidak lupa senantiasa tercurah limpahkan kepada baginda Nabi Agung Muhammad Saw yang telah membawa kita dari zaman jahiliyyah ke zaman yang terang benderan yaitu addinul Islam.

Terselesaikannya skripsi ini tidak lepas dari doa, bantuan, bimbingan, serta arahan dari berbagai pihak, karena itu peneliti mengucapkan terimakasih kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., CAHRM., CRMP, selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim.
2. Dr. Agus Mulyono, M.Kes., selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim.
3. Dr. Fachrur Rozi, M.Si., selaku Ketua Program Studi Matematika, Universitas Islam Negeri Maulana Malik Ibrahim.
4. Muhammad Nafie Jauhari, M.Si., selaku Dosen Pembimbing I yang senantiasa memberikan berbagai pengetahuan, nasehat, motivasi, dan arahan selama proses penyusunan skripsi ini.
5. Dr. Mohammad Jamhuri, M.Si., selaku Dosen Pembimbing II yang telah memberikan arahan dan masukan dalam menyusun skripsi ini.
6. Hisyam Fahmi, M.Kom., selaku Ketua Penguji yang telah meluangkan waktu, tenaga, dan perhatian dalam memberikan masukan, arahan, serta koreksi yang sangat berharga demi penyempurnaan skripsi ini. Saran dan pandangan beliau menjadi dorongan penting bagi penulis untuk meningkatkan kualitas penelitian ini.
7. Muhammad Khudzaifah, M.Si., selaku Penguji I yang dengan penuh kesabaran memberikan kritik, saran, serta bimbingan selama proses ujian dan perbaikan skripsi. Setiap masukan yang diberikan sangat membantu penulis dalam memperbaiki kekurangan dan menyempurnakan penulisan skripsi ini
8. Seluruh Dosen Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim
9. Ibu penulis, Mansurotin, yang dengan ketulusan tak pernah berhenti menyebut nama penulis dalam setiap doa, yang diam-diam menyimpan

lelahnya sendiri demi memastikan penulis tetap kuat, serta yang selalu menjadi tempat pulang ketika dunia terasa terlalu berat. Kasih sayang beliau adalah kekuatan paling sunyi yang menjaga penulis untuk tidak menyerah hingga skripsi ini dapat diselesaikan.

10. Bapak penulis, Muhammad Ishaq, yang dengan caranya sendiri selalu menguatkan langkah penulis, memberikan dukungan tanpa banyak kata, serta menghadirkan keteguhan yang menjadi sandaran dalam setiap proses yang tidak mudah. Dalam diamnya, beliau adalah alasan penulis tetap berdiri dan terus melangkah hingga mampu menyelesaikan skripsi ini.
11. Seluruh mahasiswa angkatan 2022 yang memberikan support.
12. Seluruh teman-teman yang senantiasa memberikan bantuan, dukungan dan semangat kepada penulis dalam berbagai kondisi.
13. Seluruh pihak yang sudah terlibat secara langsung maupun tidak langsung yang tidak bisa penulis tuliskan satu per satu.

Dengan seluruh kerendahan hati, penulis menyadari skripsi ini masih belum bisa dikatakan sempurna. Maka dari itu, penulis berharap kritik dan saran yang membangun untuk penyempurnaan draf skripsi ini. Semoga karya ini mampu memberikan manfaat bagi orang banyak. Aamin ya Rabbal ‘Alamin.

Malang, 02 Juni 2026

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGANTAR	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTO	vi
PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiii
DAFTAR LAMPIRAN	xiv
ABSTRAK	xv
ABSTRACT	xvi
مستخلص البحث	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian	5
1.4 Manfaat Penelitian	5
1.5 Batasan Masalah	6
BAB II KAJIAN TEORI	7
2.1 Sistem Rekomendasi	7
2.2 Sistem Rekomendasi Film Multi-Kriteria	7
2.3 Algoritma <i>Greedy</i> dalam Sistem Rekomendasi	8
2.4 <i>Diversity penalty</i>	12
2.5 Metrik Evaluasi	13
2.5.1 <i>Genre Match Ratio</i>	15
2.5.2 Intra-List Diversity (ILD)	16
2.5.3 <i>Precision@K</i>	17
2.6 Kajian Integrasi Topik dengan Al-Quran/Hadits	18
BAB III METODE PENELITIAN	21
3.1 Jenis Penelitian	21
3.2 Data dan Sumber Data	21
3.3 Tahapan Penelitian	22
BAB IV HASIL DAN PEMBAHASAN	27
4.1 Praproses Data	27
4.1.1 Pemeriksaan Awal Dataset	27
4.1.2 Pembersihan Data	27
4.2 Identifikasi Preferensi Pengguna	28
4.2.1 Pembagian Data	29
4.2.2 Perhitungan Preferensi Genre Pengguna	30
4.2.3 Representasi Preferensi Pengguna	30
4.3 Pemilihan Kandidat Film	31
4.3.1 Pengambilan Data Film	32

4.3.2 Penyaringan Film yang Telah Ditonton.....	32
4.3.3 Pembentukan Kandidat Rekomendasi	32
4.4 Perancangan Model dan Perhitungan Skor	33
4.4.1 Penambahan Atribut Data Kandidat Film	33
4.4.2 Normalisasi Atribut	34
4.4.3 Perhitungan Kesesuaian Genre.....	36
4.4.4 Perhitungan Skor Akhir.....	36
4.4.5 Implementasi Algoritma <i>Greedy</i>	37
4.4.6 Penerapan <i>Diversity Penalty</i>	38
4.5 Evaluasi pada Pengguna yang Dijadikan Sampel	41
4.5.1 <i>Genre Match Ratio</i>	41
4.5.2 Intra-List Diversity (ILD).....	42
4.5.3 Precision@K.....	43
4.5.4 Rekapitulasi Hasil Evaluasi	44
4.6 Evaluasi Keseluruhan Sistem	44
4.6.1 Hasil Evaluasi Keseluruhan.....	44
4.6.2 Analisis Hasil Evaluasi.....	45
4.7 Analisis Hasil Rekomendasi.....	46
4.7.1 Analisis Genre Dominan	47
4.7.2 Analisis Tingkat Diversitas Rekomendasi.....	47
4.7.3 Analisis Variasi Genre.....	48
4.7.4 Analisis Proporsi Film Baru (<i>Recency</i>)	48
4.7.5 Karakteristik Umum Hasil Rekomendasi.....	49
4.8 Eksperimen dan Analisis Hasil Eksperimen	49
4.8.1 Eksperimen Ruang Kandidat	50
4.8.2 Eksperimen Bobot Kriteria.....	51
4.8.3 Eksperimen Parameter Lambda.....	53
4.8.4 Analisis dan Keputusan Konfigurasi	56
4.9 Integrasi Nilai Islam dalam Sistem Rekomendasi.....	57
4.9.1 Pendekatan Filter Konten	58
4.9.2 Rancangan Mekanisme Filter Konten	58
4.9.3 Relevansi dengan Tujuan Penelitian.....	59
BAB V PENUTUP	60
5.1 Kesimpulan.....	60
5.2 Saran.....	61
DAFTAR PUSTAKA	63
LAMPIRAN.....	66
RIWAYAT HIDUP	67

DAFTAR GAMBAR

Gambar 3.1 <i>Flowchart</i> Penelitian	25
Gambar 3.2 <i>Flowchart</i> Algoritma <i>Greedy</i>	26

DAFTAR TABEL

Tabel 4.1	Contoh Hasil Pembagian Data Latih dan Data Uji	30
Tabel 4.2	Frekuensi Genre Pada Data Latih Ketiga User	31
Tabel 4.3	Jumlah Film Kandidat Ketiga User Setelah Penyaringan.....	32
Tabel 4.4	Contoh Hasil Penambahan Data Kandidat Film User 414.....	35
Tabel 4.5	Contoh Hasil Normalisasi Atribut Kandidat Film User 414.....	35
Tabel 4.6	Contoh Hasil Perhitungan Genre Score User 414.....	36
Tabel 4.7	Contoh Hasil Perhitungan Skor Akhir Kandidat Film User 414 ...	37
Tabel 4.8	Hasil Rekomendasi Film untuk User 1	40
Tabel 4.9	Hasil Rekomendasi Film untuk User 414	40
Tabel 4.10	Hasil Rekomendasi Film untuk User 610	41
Tabel 4.11	Hasil Genre Match Ratio Ketiga User	42
Tabel 4.12	Hasil Intra-List Diversity (ILD) Ketiga User.....	43
Tabel 4.13	Hasil Precision@K Ketiga User	44
Tabel 4.14	Rekapitulasi Hasil Evaluasi Ketiga User	44
Tabel 4.15	Hasil Evaluasi Keseluruhan Sistem All Candidate	45
Tabel 4.16	Perbandingan Hasil Evaluasi Pendekatan Ruang Kandidat.....	50
Tabel 4.17	Hasil Eksperimen Variasi Bobot Kriteria	52
Tabel 4.18	Hasil Eksperimen Variasi Parameter Lambda	54
Tabel 4.19	Hasil Eksperimen Lambda dengan Konfigurasi Bobot Ekstrem ...	55

DAFTAR LAMPIRAN

Lampiran 1 Contoh Coding Perencanaan Model	66
---	----

ABSTRAK

Musa'adah, Siti Ma'rifatul. 2026. *Sistem Rekomendasi Film Multi-Kriteria Berbasis Algoritma Greedy dengan Diversity Penalty*. Skripsi. Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Mohammad Nafie Jauhari, M.Si. (II) Dr. Mohammad Jamhuri, M.Si.

Kata Kunci: Sistem Rekomendasi, Multi-kriteria, Algoritma *Greedy*, *Diversity Penalty*, MovieLens

Perkembangan platform *streaming* film yang pesat menyebabkan pengguna dihadapkan pada ribuan pilihan konten. Sistem rekomendasi berbasis algoritma *greedy* standar cenderung menghasilkan rekomendasi yang monoton karena hanya mengoptimalkan akurasi lokal tanpa mempertimbangkan keberagaman, yang dikenal sebagai masalah *overspecialization*. Penelitian ini bertujuan merancang sistem rekomendasi film multi-kriteria berbasis algoritma *greedy* yang diintegrasikan dengan mekanisme *diversity penalty*, serta menganalisis pengaruh variasi bobot kriteria dan parameter λ terhadap akurasi dan keberagaman rekomendasi. Sistem dikembangkan menggunakan dataset MovieLens dengan empat kriteria penilaian, yaitu kesesuaian genre, rata-rata *rating* dengan *time decay*, popularitas, dan *recency*. Evaluasi dilakukan terhadap 610 pengguna menggunakan metrik *Genre Match Ratio*, *Intra-List Diversity* (ILD), dan *Precision@K*. Hasil menunjukkan bahwa nilai *Precision@K* cenderung optimal pada λ kecil, dengan nilai tertinggi sebesar 0,082 dicapai pada konfigurasi $\lambda = 0,05$ dengan bobot popularitas 0,50, genre 0,20, *rating* 0,20, dan *recency* 0,10. Sebaliknya, nilai ILD tertinggi sebesar 0,993 dicapai pada konfigurasi $\lambda = 0,50$ dengan bobot genre 0,55, *rating* 0,20, popularitas 0,15, dan *recency* 0,10. Temuan ini mengindikasikan adanya *trade-off* antara akurasi dan keberagaman rekomendasi, di mana pemilihan konfigurasi optimal bergantung pada prioritas sistem yang dikembangkan.

ABSTRACT

Musa'adah, Siti Ma'rifatul. 2026. **A Multi-Criteria Movie Recommendation System Based on the Greedy Algorithm with a Diversity Penalty**. Thesis. Department of Mathematics, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Advisors: (I) Mohammad Nafie Jauhari, M.Si. (II) Dr. Mohammad Jamhuri, M.Si.

Keywords: Recommendation System, Multi-criteria, Greedy algorithm, Diversity Penalty, MovieLens

The rapid development of movie streaming platforms has left users facing thousands of content options. Recommendation systems based on standard greedy algorithms tend to produce monotonous recommendations because they only optimize local accuracy without considering diversity, a phenomenon known as the overspecialization problem. This research aims to design a multi-criteria movie recommendation system based on a greedy algorithm integrated with a diversity penalty mechanism, and to analyze the impact of variations in criterion weights and the lambda parameter on the recommendation accuracy and diversity. The system was developed using the MovieLens dataset with four criteria: genre match, average rating with time decay, popularity, and recency. Evaluation was conducted on 610 users using the Genre Match Ratio, Intra-List Diversity (ILD), and Precision@K metrics. The results show that the Precision@K value tends to be optimal at small values of λ , with the highest value of 0.082 achieved at the configuration $\lambda = 0,05$ with weights of popularity 0,50, genre 0,20, rating 0,20, and recency 0,10. Conversely, the highest ILD value of 0,993 was achieved with a configuration of $\lambda = 0,50$, with weights of genre 0,55, rating 0,20, popularity 0,15, and recency 0,10. These findings indicate a trade-off between accuracy and diversity of recommendations, where the selection of the optimal configuration depends on the priorities of the system being developed.

مستخلص البحث

المساعدة، سيتي معرفة. ٢٠٢٦. نظام توصية الأفلام متعدد المعايير القائم على خوارزمية الجشع (*Greedy*) مع التنوع (*Diversity Penalty*). البحث العلمي. قسم الرياضيات، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية بمالانج. المشرفان: (١) محمد نافع جوهرى، الماجستير في العلوم (٢) دكتور محمد جمهوري، الماجستير في العلوم

الكلمات الأساسية: نظام التوصية، متعدد المعايير، خوارزمية الجشع، عقوبة التنوع، *MovieLens*

أدى التطور السريع لمنصات بث الأفلام إلى إتاحة آلاف الخيارات من المحتوى للمستخدمين. تميل أنظمة التوصية القائمة على الخوارزميات الجشعة القياسية إلى تقديم توصيات رتيبة، لأنها تكتفي بتحسين الدقة المحلية دون مراعاة التنوع، وهو ما يُعرف بمشكلة الإفراط في التخصص. هدف هذا البحث إلى تصميم نظام لتوصية الأفلام متعدد المعايير يعتمد على خوارزمية الجشع (*greedy*) مدججة مع آلية عقوبة التنوع (*diversity penalty*)، بالإضافة إلى تحليل تأثير تباين أوزان المعايير ومعامل لامدا على دقة التوصيات وتنوعها. تم تطوير النظام باستخدام مجموعة بيانات *MovieLens* التي تتضمن أربعة معايير تقييم، وهي: ملاءمة النوع، ومتوسط التقييم مع تضاد زمني، والشعبية، وحدثة الفيلم. أظهرت النتائج أن قيمة $Precision@K$ تميل إلى أن تكون مثالية عند قيم λ الصغيرة، حيث تم تحقيق أعلى قيمة لها عند 0.082 في التكوين $\lambda = 0.05$ مع الأوزان التالية: الشعبية = 0.050 ، النوع = 0.20 ، التقييم = 0.20 ، والحدثة = 0.10 . على العكس من ذلك، تم تحقيق أعلى قيمة لـ *ILD* عند 0.993 في التكوين $\lambda = 0.05$ مع وزن النوع = 0.55 ، والتقييم = 0.20 ، والشعبية = 0.15 ، والحدثة = 0.10 . تشير هذه النتائج إلى وجود مفاضلة بين دقة التوصيات وتنوعها، حيث يعتمد اختيار التكوين الأمثل على أولويات النظام الذي يتم تطويره.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sistem rekomendasi adalah bagian dari sistem penyaring informasi yang dibuat untuk memprediksi preferensi pengguna dan memberikan saran atau pilihan item yang paling sesuai dengan minatnya (Isinkaye dkk., 2015). Sistem ini bekerja dengan menganalisis preferensi sebelumnya dari pengguna dan memanfaatkan informasi tersebut untuk mencari konten serupa yang ada di *database*, seperti film dengan aktor utama, sutradara, dan genre yang sama (Naminas, 2022). Dalam konteks era digital yang dipenuhi dengan ledakan informasi, sistem rekomendasi berfungsi untuk menyaring informasi yang besar dan memberikan konten yang dipersonalisasi kepada pengguna (Isinkaye dkk., 2015). Sistem ini tidak hanya membantu pengguna menemukan konten yang relevan, tetapi juga memperkenalkan mereka pada pilihan baru dan beragam yang mungkin terlewatkan (Soham, 2025). Dengan kemampuan tersebut, sistem rekomendasi telah terbukti sebagai alat yang efektif untuk menangani masalah *information overload*, di mana pengguna merasa terbebani oleh banyaknya pilihan yang harus diproses untuk pengambilan keputusan (Jayalakshmi dkk., 2022).

Implementasi sistem rekomendasi menjadi sangat relevan dalam konteks *platform streaming* film, di mana pengguna dihadapkan pada ribuan pilihan konten yang tersedia (Kalmykov, 2023). Perkembangan teknologi informasi dan komunikasi telah mendorong dominasi *platform streaming* seperti Netflix, Disney+, dan Amazon Prime Video, yang menciptakan era baru dalam konsumsi konten film dan mengubah industri hiburan (Lopez, 2024). Pada tahun 2024,

industri media dan hiburan global mencapai pendapatan US\$2,9 triliun, naik 5,5% dari tahun sebelumnya (Spiegel, 2025). Netflix sebagai salah satu *platform streaming* terbesar melayani lebih dari 282 juta pelanggan dengan preferensi serta kebiasaan menonton yang beragam, yang menghadirkan tantangan tersendiri dalam menyediakan rekomendasi konten yang relevan bagi setiap individu di tengah koleksi konten yang terus berkembang (Antoniuk, 2025). Implementasi sistem rekomendasi terbukti meningkatkan kepuasan pengguna, mengurangi waktu pencarian konten, serta membantu *platform streaming* mempertahankan basis pelanggan dalam persaingan industri yang ketat (Fink, 2024).

Berbagai penelitian telah dilakukan untuk mengembangkan sistem rekomendasi film dengan pendekatan yang beragam, namun masih terdapat keterbatasan yang perlu diatasi. Algoritma *greedy* telah terbukti efisien dalam sistem rekomendasi karena kemampuannya melakukan optimasi lokal dengan kompleksitas komputasi yang rendah (Benouaret dkk., 2019). Namun, pendekatan *greedy* standar cenderung menghasilkan rekomendasi yang monoton karena hanya fokus pada optimasi akurasi lokal tanpa mempertimbangkan keberagaman hasil, yang dikenal sebagai masalah *overspecialization* (Kotkov dkk., 2018). Penelitian tentang diversifikasi rekomendasi telah menggunakan berbagai metrik untuk mengukur keragaman, namun implementasi *diversity* dalam konteks multi-kriteria masih terbatas dan belum terintegrasi secara optimal dengan algoritma *greedy* (Vargas & Castells, 2011). Kondisi ini menunjukkan perlunya pendekatan baru yang menggabungkan kelebihan algoritma *greedy* dengan metode diversifikasi dalam konteks multi-kriteria, sehingga sistem rekomendasi dapat menghasilkan saran yang lebih relevan, lebih beragam, dan lebih sesuai dengan kebutuhan

pengguna. Pemilihan domain film dalam penelitian ini juga memiliki urgensi tersendiri, karena jumlah film yang terus bertambah menyebabkan pengguna sering mengalami kesulitan memilih tontonan yang sesuai preferensi mereka. Selain itu, dataset film seperti MovieLens sangat matang dan banyak digunakan sebagai standar penelitian, serta memiliki fitur kaya seperti genre, *rating*, popularitas, dan *recency* yang ideal untuk diuji dalam model multi-kriteria dan diversifikasi.

Untuk mengatasi keterbatasan keragaman rekomendasi tersebut, penelitian ini mengembangkan sistem rekomendasi film multi-kriteria menggunakan algoritma *greedy* dengan integrasi *diversity penalty*. Algoritma *greedy* merupakan salah satu pendekatan yang efisien dalam sistem rekomendasi karena kemampuannya dalam melakukan optimasi lokal dengan kompleksitas komputasi yang rendah (Benouaret dkk., 2019). Algoritma ini bekerja secara iteratif dengan memilih item dari daftar kandidat dan memindahkannya ke daftar rekomendasi berdasarkan skor optimal lokal pada setiap langkah (Kotkov dkk., 2018). Namun, kelemahan utama dari algoritma *greedy* dalam konteks sistem rekomendasi adalah kecenderungannya untuk menghasilkan rekomendasi yang monoton atau seragam karena hanya fokus pada optimasi akurasi lokal, yang dikenal sebagai masalah *overspecialization* (Kotkov dkk., 2018). Hal ini menyebabkan pengguna kurang tereksplorasi terhadap konten baru yang potensial dan mengurangi pengalaman penemuan konten yang beragam atau *serendipity* (Kotkov dkk., 2018). Oleh karena itu, penelitian ini mengintegrasikan mekanisme *diversity penalty* ke dalam algoritma *greedy* berbasis multi-kriteria. Integrasi ini menjadi lebih kompleks dalam konteks multi-kriteria, di mana sistem harus menyeimbangkan tidak hanya akurasi dan keragaman, tetapi juga bobot dari berbagai kriteria seperti genre, aktor,

sutradara, dan rating secara bersamaan (Adomavicius dkk., 2010). Mekanisme *diversity penalty* yang diusulkan dirancang untuk memberikan penalti terhadap item yang terlalu mirip dengan item yang sudah dipilih berdasarkan *multiple attributes* (Kotkov dkk., 2018; Vargas & Castells, 2011), sehingga mendorong sistem untuk memilih item yang beragam dari berbagai dimensi kriteria. Pendekatan ini dirancang agar sistem dapat menghasilkan rekomendasi yang akurat sekaligus beragam untuk meningkatkan eksplorasi konten.

Dalam konteks penelitian ini, penerapan algoritma *greedy* dan mekanisme *diversity penalty* mencerminkan pentingnya penggunaan pengetahuan dan teknologi secara bijak. Hal ini sejalan dengan firman Allah dalam QS. Al-‘Alaq [96]: 1–5 (Kemenag, 2022) yang artinya:

“*Bacalah dengan (menyebut) nama Tuhanmu yang menciptakan, Dia telah menciptakan manusia dari segumpal darah. Bacalah, dan Tuhanmulah yang Maha Pemurah, yang mengajar (manusia) dengan pena, Dia mengajarkan manusia apa yang tidak diketahuinya.*”

Ayat tersebut menegaskan pentingnya ilmu pengetahuan sebagai dasar dalam pengembangan dan penerapan teknologi. Dengan demikian, penelitian ini diharapkan menjadi wujud pemanfaatan ilmu dan teknologi yang tidak hanya berorientasi pada efisiensi sistem, tetapi juga mencerminkan nilai-nilai Islam dalam menggunakan pengetahuan untuk kemaslahatan dan peningkatan manfaat bagi manusia.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengembangkan sistem rekomendasi film multi-kriteria menggunakan algoritma *greedy* dengan integrasi *diversity penalty* untuk menyeimbangkan akurasi dan keragaman hasil rekomendasi. Pendekatan ini dirancang agar lebih adaptif terhadap preferensi pengguna dengan mengurangi keseragaman hasil rekomendasi melalui

perancangan algoritma yang efisien. Hasil penelitian diharapkan dapat memberikan kontribusi ilmiah dalam pengembangan sistem rekomendasi berbasis multi-kriteria dan menjadi acuan bagi penelitian selanjutnya terkait penerapan algoritma *greedy* dalam sistem rekomendasi.

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang di atas, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana merancang dan menerapkan sistem rekomendasi film multi-kriteria berbasis algoritma *greedy* dengan *diversity penalty*?
2. Bagaimana pengaruh parameter bobot kriteria dan *diversity penalty* terhadap akurasi dan keragaman hasil rekomendasi?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Untuk mengembangkan sistem rekomendasi film berbasis multi-kriteria menggunakan algoritma *greedy* yang diintegrasikan dengan *diversity penalty*.
2. Untuk mengevaluasi pengaruh parameter bobot kriteria dan *diversity penalty* terhadap akurasi dan keragaman rekomendasi yang dihasilkan oleh model yang dikembangkan.

1.4 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Memberikan gambaran bagaimana sistem rekomendasi dapat dibuat lebih beragam.
2. Membantu pengguna memperoleh rekomendasi film yang sesuai dengan minat dan kebutuhan mereka.

3. Menjadi referensi bagi penelitian selanjutnya yang ingin mengembangkan sistem rekomendasi dengan pendekatan serupa.

1.5 Batasan Masalah

Agar penelitian ini lebih terarah dan fokus, maka ditetapkan beberapa batasan masalah sebagai berikut:

1. Dataset yang digunakan adalah MovieLens, yang berisi data film, genre, serta rating pengguna sebagai sumber utama analisis.
2. Kriteria yang dipertimbangkan dalam sistem rekomendasi meliputi rating pengguna, genre, popularitas, dan tahun rilis film.

BAB II

KAJIAN TEORI

2.1 Sistem Rekomendasi

Sistem rekomendasi merupakan perangkat lunak yang mengevaluasi preferensi pengguna, riwayat interaksi, dan fitur item untuk memberikan rekomendasi yang disesuaikan, sehingga membantu mengurangi beban informasi di *streaming* digital seperti layanan *streaming* film (Ricci dkk., 2015). Sistem ini memanfaatkan *rating* eksplisit dan perilaku implisit untuk memprediksi item yang paling relevan, sehingga dapat meningkatkan keterlibatan dan kepuasan pengguna terhadap *platform* (Bobadilla dkk., 2013). Dalam konteks rekomendasi film, sistem ini penting untuk menyaring ribuan judul berdasarkan faktor seperti genre dan rating, meskipun sering menghadapi tantangan seperti data yang jarang (*sparsity*) yang mempengaruhi akurasi prediksi terutama pada dataset besar seperti MovieLens (Su & Khoshgoftaar, 2009). Dengan kemajuan *machine learning*, sistem rekomendasi kini lebih adaptif, memungkinkan integrasi pendekatan *hybrid* yang menggabungkan berbagai metode untuk mencapai keseimbangan antara relevansi dan keragaman saran melalui evaluasi metrik seperti *precision* dan *diversity* (Isinkaye dkk., 2015).

2.2 Sistem Rekomendasi Film Multi-Kriteria

Multi-Criteria Recommender Systems (MCRS) adalah pengembangan dari sistem rekomendasi yang hanya menggunakan satu penilaian keseluruhan (*single overall rating*) menjadi sistem yang mempertimbangkan beberapa kriteria dalam proses rekomendasi (Adomavicius dkk., 2010). MCRS meningkatkan personalisasi melalui penggabungan berbagai preferensi pengguna, di mana MCRS

mempertimbangkan preferensi pengguna pada berbagai kriteria agar pengguna dapat menemukan item yang memenuhi kebutuhan spesifik mereka daripada menggunakan penilaian secara keseluruhan (Salau dkk., 2025). Gupta & Kant (2020) menyebutkan bahwa sistem rekomendasi multi-kriteria (MCRS) muncul sebagai evolusi dari sistem rekomendasi berbasis *collaborative filtering* yang hanya mengandalkan satu jenis penilaian, di mana MCRS memberikan rekomendasi item kepada pengguna berdasarkan sejumlah kriteria evaluasi yang lebih spesifik dan mendetail.

Pendekatan satu kriteria (*single-criteria approaches*) pada sistem rekomendasi tidak mampu menangkap preferensi pengguna yang multidimensional, sedangkan MCRS diakui bersifat multidimensional dengan mempertimbangkan berbagai kriteria (Salau dkk., 2025). Nassar dkk. (2020) dalam penelitiannya mengungkapkan bahwa model MCRS yang mereka kembangkan memperoleh hasil terbaik pada kedua dataset dan secara signifikan lebih baik dari model-model lainnya pada semua metrik evaluasi. Hal itu membuktikan bahwa MCRS mampu mengidentifikasi perbedaan detail dalam preferensi pengguna yang tidak bisa ditangkap oleh sistem rekomendasi yang hanya menggunakan satu kriteria penilaian.

2.3 Algoritma *Greedy* dalam Sistem Rekomendasi

Algoritma *greedy* adalah pendekatan algoritma yang membuat pilihan terbaik lokal di setiap tahapnya dengan harapan mendapatkan solusi global yang optimal (Cormen dkk., 2009). Ciri-ciri utama algoritma *greedy* adalah: (1) mengambil keputusan secara bertahap, (2) tidak membatalkan keputusan yang telah dibuat, dan (3) memiliki kompleksitas waktu yang lebih rendah dibandingkan metode

exhaustive search (Levitin, 2012). Dalam konteks optimasi, algoritma *greedy* efektif untuk masalah yang memiliki dua sifat: sifat *greedy-choice* dan struktur suboptimal. Sifat *greedy-choice* menyatakan bahwa solusi global yang optimal dapat diperoleh dengan memilih yang terbaik secara lokal, sedangkan struktur suboptimal berarti solusi terbaik dari suatu masalah mencakup solusi terbaik dari sub masalahnya (Kleinberg & Tardos, 1987).

Dalam sistem rekomendasi, algoritma *greedy* bekerja secara iteratif dengan memilih item yang memaksimalkan fungsi objektif pada setiap langkah, seperti yang diterapkan dalam berbagai pendekatan diversifikasi (Vargas & Castells, 2011). Pendekatan *greedy* standar umumnya mengoptimalkan akurasi prediksi dengan memilih item yang memiliki skor relevansi tertinggi terhadap preferensi pengguna (Cormen dkk., 2009).

Namun, pendekatan ini memiliki kelemahan signifikan, yaitu *overspecialization* (Kotkov dkk., 2018). Masalah ini menyebabkan sistem merekomendasikan item-item yang sangat mirip satu sama lain, mengurangi keberagaman dan membatasi kemampuan pengguna untuk mengeksplorasi konten baru (Ziegler dkk., 2009).

Pada penelitian ini pendekatan algoritma *greedy* yang digunakan adalah *greedy re-ranking*. *Greedy re-ranking* yaitu pendekatan yang bertujuan untuk menyusun ulang daftar kandidat item berdasarkan fungsi objektif tertentu secara iteratif (Carbonell & Goldstein, 1998). Algoritma ini bekerja dengan prinsip memilih item yang memberikan nilai optimal lokal pada setiap langkah, di mana proses *re-ranking* dilakukan setelah tahap *initial ranking* yang menghasilkan daftar kandidat berdasarkan skor relevansi (Ziegler dkk., 2009). Mekanisme kerja *greedy*

re-ranking dapat dijelaskan dalam tiga tahap utama: (1) sistem membuat daftar kandidat item yang telah diurutkan berdasarkan skor relevansi awal, (2) algoritma melakukan iterasi untuk mengevaluasi semua item dalam daftar kandidat menggunakan fungsi objektif yang mempertimbangkan tidak hanya relevansi item terhadap preferensi pengguna tetapi juga hubungannya dengan item yang sudah dipilih, dan (3) item dengan skor tertinggi dipilih dan dipindahkan ke daftar hasil rekomendasi hingga mencapai jumlah rekomendasi yang diinginkan (Santos dkk., 2010).

Secara matematis, algoritma *greedy* dalam sistem rekomendasi dirumuskan sebagai proses pemilihan item dengan nilai fungsi objektif tertinggi pada setiap iterasi, yaitu memilih elemen terbaik secara lokal dari himpunan kandidat yang tersedia (Cormen dkk., 2009). Jika C adalah himpunan kandidat dan S adalah himpunan item yang telah terpilih, maka pemilihan item pada iterasi ke- k ditentukan oleh:

$$i_k = \arg_{i \in C-S} \max f(i)$$

di mana notasi *arg max* menyatakan bahwa algoritma *greedy* memilih item yang menghasilkan nilai *final Score* tertinggi, bukan hanya nilai maksimumnya saja.

Pada penelitian ini, *final Score* $f(i)$ merupakan skor multi-kriteria yang dibentuk dari empat aspek utama, yaitu popularitas, kesesuaian genre, *rating*, dan tahun rilis (*recency*) film, yang dirumuskan sebagai berikut:

$$f(i) = \alpha \cdot \text{Popularity}(i) + \beta \cdot \text{Genre}(i) + \gamma \cdot \text{Rating}(i) + \delta \cdot \text{Recency}(i)$$

di mana $\alpha, \beta, \gamma, \delta$ merupakan bobot kepentingan dari masing-masing kriteria. Item dengan nilai $f(i)$ tertinggi akan dipilih secara bertahap oleh algoritma *greedy* hingga jumlah rekomendasi yang diinginkan terpenuhi.

Dalam konteks multi-kriteria, sistem rekomendasi dapat mempertimbangkan beberapa aspek sekaligus seperti *rating*, genre, tahun rilis, dan popularitas (Manouselis & Costopoulou, 2007). Pendekatan ini menggunakan fungsi agregasi yang menggabungkan berbagai kriteria dengan bobot tertentu untuk menghasilkan skor akhir setiap item (Jannach dkk., 2011). Penelitian ini mengintegrasikan mekanisme *diversity* ke dalam algoritma *greedy* multi-kriteria untuk menghasilkan rekomendasi yang seimbang antara akurasi dan keberagaman.

Alur algoritma *greedy* dapat direpresentasikan dalam bentuk *pseudocode* yang ditunjukkan pada Algoritma 2.1.

Algoritma 2.1 Algoritma Greedy

```

Algoritma greedy
INPUT  : candidate_movies (daftar film kandidat beserta
        final_score)
        genre_score (nilai kesesuaian genre setiap film
        kandidat)
        top_n
OUTPUT : selected_movies (daftar 10 film rekomendasi)
BEGIN
    selected_movies ← []
    WHILE panjang(selected_movies) < top_n DO
        best_movie ← NULL
        best_score ← -1
        FOR EACH film f IN candidate_movies DO
            IF final_score(f) > best_score THEN
                best_score ← final_score(f)
                best_movie ← f
            END IF
        END FOR
        IF best_movie ≠ NULL THEN
            Tambahkan best_movie ke selected_movies
            Hapus best_movie dari candidate_movies
        END IF
    END WHILE
    RETURN selected_movies
END

```

Algoritma *greedy* pada *pseudocode* tersebut bekerja dengan langsung menelusuri seluruh kandidat film pada setiap iterasi untuk mencari film dengan *final score* tertinggi, kemudian menghapusnya dari daftar kandidat dan memasukkannya ke

dalam daftar rekomendasi. Proses ini diulang hingga diperoleh sepuluh film rekomendasi. Pendekatan ini tidak mempertimbangkan kemiripan antar film yang terpilih, sehingga hasil rekomendasi berpotensi didominasi oleh film dengan genre yang serupa.

2.4 *Diversity penalty*

Sistem rekomendasi tradisional cenderung menyarankan item yang populer di antara semua pengguna dan mirip dengan item yang biasa dikonsumsi pengguna. Akibatnya, pengguna menerima rekomendasi yang sudah mereka kenal atau akan mereka temukan, yang mengarah pada kepuasan yang rendah (Kotkov dkk., 2018).

Diversity dalam sistem rekomendasi mengacu pada tingkat keberagaman item yang direkomendasikan kepada pengguna (Zhao dkk., 2025). *Diversity* terbukti memiliki dampak signifikan terhadap kepuasan pengguna karena dapat memberikan peluang eksplorasi untuk menemukan item yang baru dan menarik, serta memungkinkan sistem untuk menemukan minat baru pengguna (Chen dkk., 2018). Namun, tantangan utama dalam implementasi *diversity* adalah adanya trade-off antara akurasi dan keberagaman rekomendasi (Zhao dkk., 2025). Salah satu dilema mendasar dalam sistem rekomendasi adalah bahwa rekomendasi yang paling berguna seringkali ditemukan di antara item yang kurang populer tetapi beragam (Kotkov dkk., 2018).

Diversity penalty merupakan mekanisme yang digunakan dalam algoritma *greedy* untuk menyeimbangkan antara relevansi dan keberagaman dalam proses pemilihan item rekomendasi (Zhao dkk., 2025). Konsep ini diimplementasikan dengan memberikan penalti pada item yang terlalu mirip dengan item yang sudah

dipilih sebelumnya, sehingga mendorong sistem untuk memilih item yang lebih beragam (Carbonell & Goldstein, 1998).

Pemilihan nilai parameter λ dalam formula *diversity penalty* sangat penting untuk mencapai keseimbangan optimal antara akurasi dan *diversity* (Dergunov, 2024). Dalam beberapa implementasi, parameter ini dapat dibuat personalized dan dapat dikontrol oleh pengguna untuk memberikan fleksibilitas dalam mengatur tingkat *diversity* yang diinginkan (Zhao dkk., 2025).

Tahapan penerapan *diversity penalty* untuk direpresentasikan dalam bentuk *pseudocode* pada Algoritma 2.2. Perbedaan utama dibandingkan algoritma *greedy* tanpa penalti terletak pada penambahan loop perhitungan $\text{sim}(f, s)$ di dalam iterasi pemilihan. Setiap film kandidat tidak lagi dinilai berdasarkan *final score* semata, melainkan berdasarkan *adjusted_score* yang dihitung dengan mengurangi *final score* secara akumulatif sebesar $\lambda \times \text{sim}(f, s)$ untuk setiap film yang telah terpilih. Semakin mirip genre suatu film dengan film yang sudah masuk daftar rekomendasi, semakin besar penalti yang diterima sehingga peluangnya untuk terpilih menjadi lebih kecil.

2.5 Metrik Evaluasi

Evaluasi sistem rekomendasi merupakan upaya untuk mengukur seberapa baik sistem memberikan rekomendasi yang relevan dan berguna kepada pengguna (Carbonell & Goldstein, 1998). Evaluasi sistem rekomendasi adalah hal yang kompleks karena algoritma dapat berperforma berbeda pada dataset yang berbeda, tujuan evaluasi dapat bervariasi, dan pemilihan metrik yang tepat untuk membandingkan pendekatan individual merupakan hal yang rumit (Carbonell & Goldstein, 1998). Metrik evaluasi dalam sistem rekomendasi dapat dikelompokkan

menjadi beberapa kategori, yaitu metrik prediktif untuk menilai ketepatan rekomendasi, metrik ranking untuk mengevaluasi kualitas urutan item, dan metrik perilaku yang mencerminkan properti spesifik sistem seperti keberagaman atau kebaruan rekomendasi (Carbonell & Goldstein, 1998).

Algoritma 2.2 Diversity Penalty

```

Diversity Penalty
INPUT  : candidate_movies (daftar film kandidat beserta
        final_score)
        genre_score (nilai kesesuaian genre setiap film
        kandidat)
         $\lambda$ (parameter diversity penalty)
        top_n
OUTPUT : selected_movies (daftar 10 film rekomendasi)
BEGIN
    selected_movies  $\leftarrow$  []
    WHILE panjang(selected_movies) < top_n DO
        best_movie  $\leftarrow$  NULL
        best_score  $\leftarrow$  -1
        FOR EACH film f IN candidate_movies DO
            adjusted_score  $\leftarrow$  final_score(f)
            FOR EACH film s IN selected_movies DO
                genre_f  $\leftarrow$  himpunan genre film f
                genre_s  $\leftarrow$  himpunan genre film s
                intersection  $\leftarrow$  |genre_f  $\cap$  genre_s|
                max_genre  $\leftarrow$  max(|genre_f|, 1)
                sim(f, s)  $\leftarrow$  intersection / max_genre
                adjusted_score  $\leftarrow$  adjusted_score -  $\lambda \times$  sim(f, s)
            END FOR
            IF adjusted_score > best_score THEN
                best_score  $\leftarrow$  adjusted_score
                best_movie  $\leftarrow$  f
            END IF
        END FOR
        IF best_movie  $\neq$  NULL THEN
            Tambahkan best_movie ke selected_movies
            Hapus best_movie dari candidate_movies
        END IF
    END WHILE

    RETURN selected_movies
END

```

Penelitian ini menggunakan tiga metrik evaluasi untuk mengukur kualitas sistem rekomendasi dari aspek yang berbeda, yaitu *Genre Match Ratio*, *Intra-List Diversity* (ILD), dan *Precision@K*. Ketiga metrik ini dipilih karena mampu

memberikan gambaran yang lebih menyeluruh tentang kualitas rekomendasi dibandingkan hanya mengandalkan satu metrik tunggal, mengingat sistem rekomendasi yang baik tidak hanya dituntut akurat dalam memprediksi preferensi pengguna, tetapi juga mampu menghasilkan rekomendasi yang beragam dan sesuai dengan karakteristik pengguna (Ziegler dkk., 2009).

2.5.1 *Genre Match Ratio*

Salah satu aspek penting dalam mengevaluasi sistem rekomendasi adalah sejauh mana rekomendasi yang dihasilkan sesuai dengan preferensi pengguna (Ziegler dkk., 2009). Dalam sistem rekomendasi berbasis konten, preferensi pengguna sering direpresentasikan melalui atribut item seperti genre, kategori, atau topik (Ziegler dkk., 2009). Oleh karena itu, diperlukan metrik yang mampu mengukur tingkat kesesuaian antara karakteristik item yang direkomendasikan dengan preferensi pengguna yang telah diidentifikasi sebelumnya.

Genre Match Ratio merupakan metrik yang mengukur proporsi item dalam daftar rekomendasi yang mengandung setidaknya satu atribut genre yang sesuai dengan preferensi genre pengguna (Ziegler dkk., 2009). Metrik ini mencerminkan kemampuan sistem dalam mempertahankan relevansi rekomendasi terhadap kecenderungan tontonan pengguna tanpa harus membatasi seluruh ruang kandidat hanya pada genre tertentu (Ziegler dkk., 2009). Nilai *Genre Match Ratio* dihitung menggunakan persamaan berikut:

$$\text{Genre match ratio} = \frac{N}{K} \times 100\%$$

di mana N adalah jumlah item rekomendasi yang memuat setidaknya satu genre yang sesuai dengan preferensi pengguna dan K adalah jumlah total item rekomendasi (Ziegler dkk., 2009). Nilai *Genre Match Ratio* berkisar antara 0%

hingga 100%, di mana nilai yang lebih tinggi menunjukkan bahwa sistem lebih mampu menghasilkan rekomendasi yang sesuai dengan preferensi genre pengguna (Ziegler dkk., 2009). Penentuan genre yang dianggap sesuai bergantung pada pendekatan identifikasi preferensi yang digunakan, misalnya berdasarkan genre yang paling sering muncul dalam riwayat tontonan pengguna (Ziegler dkk., 2005).

2.5.2 Intra-List Diversity (ILD)

Sistem rekomendasi yang hanya mengoptimalkan akurasi cenderung menghasilkan daftar rekomendasi yang homogen, di mana item-item yang direkomendasikan memiliki karakteristik yang sangat mirip satu sama lain (Ziegler dkk., 2009). Kondisi ini dikenal sebagai masalah *filter bubble* yang dapat membatasi eksposur pengguna terhadap konten yang beragam (Ziegler dkk., 2009). Untuk mengukur sejauh mana suatu daftar rekomendasi terbebas dari homogenitas tersebut, digunakan metrik *Intra-List Diversity* (ILD) yang mengukur tingkat keberagaman daftar rekomendasi berdasarkan rata-rata jarak antar pasangan item yang direkomendasikan (Ziegler dkk., 2009).

Jarak antar item dihitung menggunakan *Jaccard distance* yang mengukur ketidakmiripan antara dua item berdasarkan atribut yang dimilikinya (Ziegler dkk., 2009). Dalam konteks sistem rekomendasi berbasis genre, *Jaccard distance* dihitung sebagai berikut:

$$Jaccard\ distance(f_i, f_j) = 1 - \frac{|genre_{f_i} \cap genre_{f_j}|}{|genre_{f_i} \cup genre_{f_j}|}$$

di mana f_i adalah film ke- i dan f_j adalah film ke- j dalam daftar rekomendasi, dengan $i \neq j$ (Ziegler dkk., 2009). Nilai *Jaccard distance* yang mendekati 1

menunjukkan bahwa kedua item memiliki sedikit kesamaan genre, sedangkan nilai yang mendekati 0 menunjukkan bahwa kedua item memiliki genre yang hampir identik (Ziegler dkk., 2009). Nilai ILD kemudian dihitung sebagai rata-rata *Jaccard distance* dari seluruh pasangan film:

$$ILD = \frac{2}{K(K-1)} \sum_{i=1}^K \sum_{j=i+1}^K Jaccard\ distance(f_i, f_j)$$

di mana K adalah jumlah total film rekomendasi, $\frac{2}{K(K-1)}$ adalah faktor normalisasi yang mewakili jumlah seluruh pasangan film yang mungkin (Ziegler dkk., 2009). Penjumlahan dilakukan terhadap seluruh kombinasi pasangan film (i, j) dengan $i < j$, sehingga setiap pasangan hanya dihitung satu kali. Nilai ILD berkisar antara 0 hingga 1, di mana nilai yang mendekati 1 menunjukkan bahwa item-item yang direkomendasikan memiliki keberagaman yang tinggi (Ziegler dkk., 2009).

2.5.3 *Precision@K*

Dalam konteks sistem rekomendasi, akurasi prediksi diukur berdasarkan kemampuan sistem untuk menempatkan item yang relevan dalam daftar rekomendasi yang disajikan kepada pengguna (Cremonesi dkk., 2010). Salah satu metrik yang paling umum digunakan untuk mengukur hal ini adalah *Precision@K*, yang mengukur proporsi item relevan dalam K item teratas yang direkomendasikan oleh sistem (Cremonesi dkk., 2010). Metrik ini relevan karena dalam praktiknya pengguna hanya akan melihat dan berinteraksi dengan sejumlah kecil item teratas dari daftar rekomendasi, sehingga kualitas item di posisi atas jauh lebih penting daripada kualitas keseluruhan daftar (Cremonesi dkk., 2010).

Nilai *Precision@K* dihitung menggunakan persamaan berikut:

$$Precision@K = \frac{|rekomendasi \cap item\ relevan|}{K}$$

di mana K adalah jumlah item rekomendasi yang dihasilkan dan *rekomendasi* $\cap$ *item relevan* adalah jumlah item dalam daftar rekomendasi yang termasuk dalam himpunan item relevan bagi pengguna (Cremonesi dkk., 2010). Penentuan item yang dianggap relevan bergantung pada konteks evaluasi dan dapat didefinisikan dengan berbagai pendekatan, misalnya berdasarkan *rating* aktual pengguna atau berdasarkan riwayat interaksi pengguna pada periode tertentu (Cremonesi dkk., 2010). Nilai $Precision@K$ berkisar antara 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan bahwa sistem lebih mampu memprediksi film yang relevan bagi pengguna (Cremonesi dkk., 2010).

2.6 Kajian Integrasi Topik dengan Al-Quran/Hadits

Pengembangan sistem rekomendasi film multi-kriteria berbasis algoritma *greedy* dengan *diversity penalty* merupakan bentuk penerapan ilmu pengetahuan dan teknologi untuk mempermudah akses informasi yang relevan bagi pengguna. Dalam perspektif Islam, pengembangan teknologi seperti ini memiliki landasan yang kuat dalam Al-Qur'an dan Hadits, yang menekankan pentingnya ilmu pengetahuan, pembelajaran, dan pemanfaatan teknologi untuk kemaslahatan umat manusia.

Integrasi nilai-nilai Al-Qur'an dalam penelitian ini didasarkan pada QS. Al-'Alaq [96]: 1–5 (Kemenag, 2022) yang artinya:

"Bacalah dengan (menyebut) nama Tuhanmu yang menciptakan. Dia telah menciptakan manusia dari segumpal darah. Bacalah, dan Tuhanmulah yang Maha Pemurah, yang mengajar (manusia) dengan pena. Dia mengajarkan manusia apa yang tidak diketahuinya."

Ayat ini merupakan wahyu pertama yang diturunkan kepada Nabi Muhammad SAW dan menjadi fondasi bagi umat Islam dalam mengejar ilmu pengetahuan. Menurut tafsir Ibnu Katsir, perintah "Iqra" (bacalah) bukan hanya terbatas pada membaca teks tertulis, tetapi mencakup makna yang lebih luas yaitu mempelajari, memahami, dan merenungkan segala ciptaan Allah SWT, termasuk fenomena alam dan perkembangan ilmu pengetahuan (Katsir, 1999). Kata "Al-Qalam" (pena) dalam ayat ini, sebagaimana dijelaskan oleh M. Quraish Shihab dalam Tafsir Al-Misbah, melambangkan alat dan media penyebaran ilmu pengetahuan, yang dalam konteks modern dapat diinterpretasikan sebagai teknologi informasi dan komputasi yang menjadi sarana transfer pengetahuan (Shihab, 2002).

Selain QS. Al-'Alaq, penelitian ini juga mengambil inspirasi dari QS. Ar-Ra'd [13]: 11 (Kemenag, 2022) yang menegaskan: *"Sesungguhnya Allah tidak akan mengubah keadaan suatu kaum hingga mereka mengubah keadaan diri mereka sendiri."* Tafsir Al-Azhar karya Hamka menjelaskan bahwa ayat ini mengajarkan prinsip kausalitas dan tanggung jawab manusia dalam memperbaiki kehidupannya melalui usaha dan ikhtiar, bukan hanya menunggu perubahan dari luar (Hamka, 1982). Dalam konteks pengembangan sistem rekomendasi, ayat ini mendorong peneliti dan pengembang untuk terus berinovasi menciptakan solusi teknologi yang dapat meningkatkan kualitas hidup dan mempermudah akses informasi bagi masyarakat luas. Konsep khalifah fi al-ardh (khalifah di bumi) yang disebutkan dalam QS. Al-Baqarah [2]: 30 (Kemenag, 2022) juga relevan dengan penelitian ini, di mana manusia memiliki tanggung jawab untuk mengelola dan memanfaatkan sumber daya alam dan pengetahuan secara bijaksana. Tafsir Al-Munir karya Wahbah Az-Zuhaili menjelaskan bahwa peran khalifah mengandung dimensi

amanah untuk menggunakan akal dan ilmu pengetahuan dalam memakmurkan bumi serta memberikan manfaat bagi seluruh makhluk (Az Zuhaili, 1991).

Dengan demikian, integrasi nilai-nilai Al-Qur'an dan Hadits dalam pengembangan sistem rekomendasi film multi-kriteria ini menunjukkan bahwa kemajuan teknologi tidak bertentangan dengan ajaran Islam, melainkan justru sejalan dengan perintah untuk menuntut ilmu dan menggunakannya bagi kemaslahatan umat.

BAB III

METODE PENELITIAN

3.1 Jenis Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan jenis penelitian eksperimental. Penelitian eksperimental dipilih karena bertujuan untuk menguji efektivitas algoritma *greedy* dengan *diversity penalty* dalam sistem rekomendasi film multi-kriteria melalui pengukuran variabel-variabel tertentu secara sistematis dan objektif. Metode eksperimental memungkinkan peneliti untuk mengontrol variabel independen (parameter bobot kriteria dan nilai *diversity penalty*) serta mengamati pengaruhnya terhadap variabel dependen (kualitas rekomendasi yang diukur melalui metrik akurasi, keragaman, dan kepuasan pengguna).

3.2 Data dan Sumber Data

Penelitian ini menggunakan data sekunder berupa dataset MovieLens yang disediakan oleh GroupLens Research. Dataset dapat diakses melalui link: <https://grouplens.org/datasets/movielens/latest/> Dataset ini dipilih karena sering digunakan dalam penelitian akademik sistem rekomendasi dan menyediakan data yang lengkap dengan berbagai ukuran (100K, 1M, 10M, 20M, 25M *ratings*) yang dapat disesuaikan untuk kebutuhan eksperimen. Data yang digunakan mencakup informasi film seperti judul, genre, dan tahun rilis, data rating pengguna dalam skala tertentu yang merepresentasikan tingkat kepuasan terhadap film, kategori genre berdasarkan tema seperti *action*, *comedy*, dan *drama*, informasi temporal berupa tahun rilis dan *timestamp* rating untuk mengidentifikasi tren preferensi, serta data popularitas berupa jumlah rating sebagai indikator popularitas film. Pemilihan

MovieLens didasarkan pada kelengkapan atribut multi-kriteria yang diperlukan untuk mengimplementasikan algoritma *greedy* dengan *diversity penalty*.

3.3 Tahapan Penelitian

Penelitian ini dilaksanakan melalui beberapa tahapan sistematis sesuai Gambar 3.1 untuk mengembangkan sistem rekomendasi film menggunakan algoritma *greedy* dengan *diversity penalty*.

1. Praproses data

Pada tahap ini dilakukan pengumpulan dan pembersihan data dari dataset MovieLens, yang terdiri dari data film dan rating pengguna. Sebelum dibersihkan, data diperiksa terlebih dahulu meliputi jumlah entri, tipe data setiap atribut, *missing values*, dan duplikasi pada masing-masing dataset. Selanjutnya, dilakukan pembersihan dengan cara menghapus data yang tidak sesuai. Data *rating* kemudian dibagi menjadi data latih dan data uji dengan proporsi 80:20 berdasarkan urutan waktu (*timestamp*) untuk setiap pengguna.

2. Identifikasi preferensi pengguna

Sistem menentukan preferensi pengguna berdasarkan riwayat *rating* pada data latih. Dari data tersebut dihitung frekuensi kemunculan setiap genre dari seluruh film yang pernah ditonton, kemudian diidentifikasi tiga genre dengan frekuensi tertinggi (*top-3*) sebagai representasi preferensi genre pengguna yang menjadi dasar perhitungan kesesuaian film (*genre match score*) pada proses rekomendasi.

3. Pemilihan kandidat film

Film yang belum pernah ditonton oleh pengguna dipilih sebagai kandidat rekomendasi, di mana informasi film yang telah ditonton diperoleh dari data

latih. Setiap film kandidat kemudian diperkaya dengan atribut tambahan meliputi popularitas, tahun rilis, dan rata-rata *rating*, yang selanjutnya dinormalisasi menggunakan metode *min-max normalization* agar seluruh fitur numerik berada dalam skala yang seimbang sebelum dihitung dalam model.

4. Perancangan model dan perhitungan skor

Sistem rekomendasi dirancang menggunakan pendekatan algoritma *greedy*. Skor setiap film kandidat dihitung berdasarkan empat kriteria, yaitu *rating* yang telah dikenakan *time decay*, kesesuaian genre (*genre match score*), popularitas, dan *recency*, dengan bobot masing-masing sebesar 0,25. Nilai *genre match score* dihitung berdasarkan proporsi genre favorit pengguna yang terdapat dalam film kandidat, sehingga film dengan genre yang lebih sesuai dengan preferensi pengguna akan mendapatkan skor yang lebih tinggi. Selanjutnya, algoritma *greedy* digunakan untuk memilih film secara bertahap dengan menerapkan parameter lambda $\lambda = 0,3$ sebagai *diversity penalty* yang memberikan penalti terhadap film yang memiliki kemiripan genre tinggi dengan film yang telah terpilih sebelumnya, sehingga mendorong keberagaman dalam daftar rekomendasi. Sepuluh film dengan skor tertinggi diambil sebagai hasil rekomendasi.

5. Evaluasi pada pengguna sampel

Evaluasi dilakukan terhadap tiga pengguna sampel (User ID 1, 414, dan 610) untuk mengilustrasikan hasil rekomendasi secara mendalam. Metrik evaluasi yang digunakan meliputi *Genre Match Ratio* untuk mengukur kesesuaian genre rekomendasi terhadap preferensi pengguna, *Intra-List Diversity* (ILD)

untuk mengukur tingkat keberagaman daftar rekomendasi, dan *Precision@K* untuk mengukur akurasi prediksi sistem terhadap film yang relevan bagi pengguna.

6. Evaluasi keseluruhan sistem


Evaluasi dilakukan terhadap seluruh 610 pengguna dalam dataset menggunakan pendekatan *all candidate*. Hasil evaluasi disajikan dalam bentuk rata-rata ketiga metrik *Genre Match Ratio*, *ILD*, dan *Precision@K* untuk memberikan gambaran umum tentang performa sistem secara keseluruhan.

7. Analisis hasil rekomendasi


Analisis dilakukan terhadap sepuluh film teratas untuk menilai genre dominan, tingkat diversitas, variasi genre, proporsi film baru, serta karakteristik umum hasil rekomendasi menggunakan pendekatan *all candidate*.

8. Eksperimen dan analisis hasil eksperimen

Tahap ini dilakukan untuk menguji pengaruh variasi metode dan parameter terhadap kualitas rekomendasi. Eksperimen meliputi perbandingan pendekatan ruang kandidat (*all candidate* vs *genre filtering*), variasi bobot kriteria, dan variasi parameter λ . Setiap eksperimen dievaluasi menggunakan *Precision@K* dan *ILD* untuk memahami pola *trade-off* antara akurasi dan keberagaman rekomendasi yang dihasilkan.

Gambar 3.1 *Flowchart* Penelitian

Alur kerja algoritma *greedy* pada sistem rekomendasi film direpresentasikan dalam bentuk *flowchart* pada Gambar 3.2. *Flowchart* tersebut menggambarkan tahapan proses pemilihan item rekomendasi secara bertahap berdasarkan nilai evaluasi tertinggi pada setiap iterasi hingga jumlah rekomendasi terpenuhi.



Gambar 3.2 *Flowchart* Algoritma *Greedy*

BAB IV

HASIL DAN PEMBAHASAN

4.1 Praproses Data

Tahap praproses data merupakan langkah awal penelitian untuk menyiapkan dataset MovieLens agar siap digunakan dalam sistem rekomendasi film berbasis algoritma *greedy* dengan *diversity penalty*. Dataset yang digunakan adalah MovieLens Latest Small (ml-latest-small) yang dapat diakses melalui link: <https://grouplens.org/datasets/movielens/latest/>. Dataset terdiri dari dua file utama, yaitu *movies.csv* dan *ratings.csv*. Dataset awal memuat 9.742 film, 100.836 rating, dan 610 pengguna, dengan rentang rating dari 0,5 hingga 5,0.

4.1.1 Pemeriksaan Awal Dataset

Pemeriksaan awal dilakukan untuk mengetahui kondisi dataset sebelum diproses lebih lanjut, meliputi jumlah entri, tipe data, serta keberadaan nilai hilang (*missing values*) dan duplikasi. Pemeriksaan dilakukan dengan menghitung jumlah baris dan kolom pada masing-masing dataset, mengidentifikasi tipe data setiap atribut, serta menghitung jumlah nilai hilang dan data duplikat. Hasil pemeriksaan menunjukkan bahwa data film terdiri dari 9.742 entri dengan atribut *movieId*, *title*, dan *genres*, serta tidak memiliki nilai hilang maupun duplikasi. Data rating terdiri dari 100.836 entri dengan atribut *userId*, *movieId*, *rating*, dan *timestamp*, yang juga tidak memiliki nilai hilang dan duplikasi. Dengan demikian, dataset berada dalam kondisi baik dan siap untuk tahap pembersihan.

4.1.2 Pembersihan Data

Pembersihan data dilakukan untuk menyesuaikan dataset dengan kebutuhan sistem rekomendasi. Pada tahap ini dilakukan penyaringan data yang tidak

relevan, khususnya pada atribut genres. Sebanyak 34 film dengan label (*no genres listed*) dihapus karena tidak memiliki informasi genre yang diperlukan dalam perhitungan *diversity penalty*. Selain itu, langkah ini bertujuan untuk menjaga konsistensi representasi fitur yang digunakan dalam proses rekomendasi. Dengan memastikan setiap film memiliki genre yang jelas, proses perhitungan diversitas dapat dilakukan secara lebih akurat.

Setelah pembersihan, jumlah film menjadi 9.708, sedangkan jumlah *rating* dan pengguna tetap, yaitu masing-masing 100.836 dan 610. Hal ini menunjukkan bahwa penghapusan tidak mempengaruhi data interaksi pengguna. Secara keseluruhan, pengurangan data relatif kecil ($\pm 0,36\%$), sehingga dataset dinilai memiliki kualitas yang baik dan siap digunakan pada tahap selanjutnya.

4.2 Identifikasi Preferensi Pengguna

Tahap ini bertujuan untuk mengidentifikasi preferensi pengguna sebagai dasar dalam proses rekomendasi film. Dalam penelitian ini, digunakan tiga pengguna sebagai sampel untuk mengilustrasikan proses pembentukan rekomendasi, yaitu pengguna dengan *userId* 1, 414, dan 610. Pemilihan ketiga pengguna ini mempertimbangkan variasi karakteristik, seperti jumlah *rating* yang diberikan dan kecenderungan preferensi genre. *User* 1 dipilih sebagai representasi pengguna dengan jumlah *rating* yang relatif sedikit, sehingga dapat menggambarkan bagaimana sistem bekerja pada pengguna dengan riwayat tontonan yang terbatas. *User* 414 dipilih sebagai representasi pengguna dengan jumlah *rating* yang banyak dan preferensi genre yang beragam, sehingga dapat menggambarkan bagaimana sistem menangani pengguna dengan profil preferensi yang kaya. *User* 610 dipilih sebagai representasi pengguna dengan karakteristik yang

berada di antara keduanya. Dengan memilih pengguna yang memiliki karakteristik yang berbeda-beda, hasil ilustrasi yang diperoleh diharapkan dapat mencerminkan kinerja sistem secara lebih menyeluruh. Selanjutnya, ketiga pengguna tersebut digunakan sebagai contoh dalam setiap tahapan proses identifikasi preferensi hingga pembentukan rekomendasi.

4.2.1 Pembagian Data

Sebelum proses identifikasi preferensi dilakukan, data *rating* masing-masing pengguna sampel dibagi menjadi dua himpunan, yaitu data latih (*training data*) dan data uji (*testing data*). Data terlebih dahulu diekstraksi per pengguna, kemudian diurutkan secara kronologis berdasarkan nilai *timestamp*. Pengurutan ini bertujuan untuk mempertahankan urutan temporal dalam riwayat tontonan, sehingga pembagian data mencerminkan kondisi yang lebih realistis. Sistem hanya menggunakan informasi masa lalu untuk memprediksi preferensi di masa mendatang.

Pembagian dilakukan dengan proporsi 80:20, di mana 80% data awal digunakan sebagai data latih dan 20% data akhir digunakan sebagai data uji. Proporsi ini dipilih karena secara umum digunakan dalam penelitian sistem rekomendasi untuk memastikan model memiliki data yang cukup dalam membangun profil preferensi pengguna sekaligus menyisakan data yang memadai untuk evaluasi. Data latih merepresentasikan riwayat tontonan awal pengguna yang digunakan untuk membangun profil preferensi, sedangkan data uji merepresentasikan film-film yang ditonton pada periode berikutnya dan digunakan untuk mengevaluasi hasil rekomendasi. Hasil pembagian data untuk ketiga pengguna sampel disajikan pada Tabel 4.1.

Tabel 4.1 Contoh Hasil Pembagian Data Latih dan Data Uji

User ID	Total Data	Data <i>Train</i> (80%)	Data Test (20%)
1	232	185	47
414	2.698	2.158	540
610	1.302	1.041	261

Selanjutnya, data latih digabungkan dengan informasi film dari dataset *movies*, mencakup genre dan tahun rilis yang diekstraksi dari judul film. Penggabungan ini diperlukan agar proses perhitungan preferensi genre dapat dilakukan pada tahap berikutnya. Selain itu, setiap film juga dilengkapi dengan nilai popularitas yang dihitung berdasarkan jumlah total *rating* yang diterima dari seluruh pengguna dalam dataset.

4.2.2 Perhitungan Preferensi Genre Pengguna

Preferensi genre pengguna dihitung berdasarkan data latih yang telah diperoleh pada tahap sebelumnya. Karena setiap film dapat memiliki lebih dari satu genre yang dipisahkan dengan karakter *pipe* (|) dalam dataset maka dilakukan proses pemisahan (*splitting*) genre menjadi elemen-elemen individual sebelum perhitungan dilakukan.

Setelah genre dipisahkan, frekuensi kemunculan setiap genre dihitung dari keseluruhan film yang terdapat dalam data latih pengguna. Genre dengan frekuensi kemunculan yang lebih tinggi diasumsikan mencerminkan tingkat preferensi yang lebih besar dari pengguna terhadap genre tersebut. Hasil perhitungan preferensi genre untuk ketiga pengguna sampel disajikan pada Tabel 4.2.

4.2.3 Representasi Preferensi Pengguna

Frekuensi genre yang telah diperoleh selanjutnya digunakan sebagai representasi preferensi pengguna dalam bentuk bobot per genre. Bobot ini bersifat

relatif dan mencerminkan seberapa dominan suatu genre dalam riwayat tontonan pengguna pada data latih. Representasi berbasis bobot ini memungkinkan sistem untuk mengukur kesesuaian antara profil preferensi pengguna dengan karakteristik genre suatu film secara lebih terstruktur, khususnya pada film yang memiliki lebih dari satu genre. Profil preferensi genre yang terbentuk ini selanjutnya digunakan sebagai salah satu komponen utama dalam proses pemilihan kandidat film dan perhitungan *genre match* pada tahap berikutnya.

Tabel 4.2 Frekuensi Genre Pada Data Latih Ketiga User

Genre	User 1	User 414	User 610
Action	90	668	517
Adventure	85	457	267
Comedy	83	1.079	411
Drama	68	1.309	479
Thriller	55	625	510
Fantasy	47	226	151
Crime	45	416	273
Children	42	177	56
Sci-Fi	40	323	251
Animation	29	124	66
Romance	26	509	119
War	22	124	47
Musical	22	110	14
Mystery	18	150	120
Horror	17	132	303
Western	7	52	33
Film-Noir	1	14	10
Documentary	0	62	5
IMAX	0	57	82

4.3 Pemilihan Kandidat Film

Tahap ini bertujuan untuk menentukan sekumpulan film yang akan dipertimbangkan dalam proses perhitungan skor rekomendasi. Kandidat film didefinisikan sebagai film-film yang belum pernah ditonton oleh pengguna berdasarkan data latih, sehingga sistem hanya mempertimbangkan film yang benar-benar baru bagi pengguna.

4.3.1 Pengambilan Data Film

Data film diambil dari dataset MovieLens yang telah melalui tahap praproses, mencakup informasi identitas film (*movieId*), judul, dan genre. Seluruh data film ini digunakan sebagai kumpulan awal sebelum dilakukan proses penyaringan.

4.3.2 Penyaringan Film yang Telah Ditonton

Dari keseluruhan data film, dilakukan penyaringan dengan menghapus film yang sudah terdapat dalam data latih pengguna. Proses ini memastikan bahwa sistem hanya merekomendasikan film yang belum pernah ditonton, sehingga hasil rekomendasi tidak bersifat redundan. Jumlah kandidat film yang tersisa untuk setiap pengguna sampel disajikan pada Tabel 4.3.

Tabel 4.3 Jumlah Film Kandidat Ketiga User Setelah Penyaringan

User ID	Total Film	Film Ditonton (Data Train)	Film Kandidat
1	9.708	185	9.523
414	9.708	2.158	7.550
610	9.708	1.041	8.667

Jumlah kandidat film yang tersisa berbeda untuk setiap pengguna. Semakin banyak film yang telah ditonton, semakin sedikit kandidat yang tersedia.

4.3.3 Pembentukan Kandidat Rekomendasi

Film-film yang lolos proses penyaringan selanjutnya ditetapkan sebagai kandidat rekomendasi. Kumpulan kandidat ini kemudian menjadi input pada tahap berikutnya, yaitu perancangan model dan perhitungan skor, di mana setiap film kandidat akan dievaluasi berdasarkan beberapa kriteria untuk menentukan urutan rekomendasi yang optimal.

4.4 Perancangan Model dan Perhitungan Skor

Tahap ini bertujuan untuk menghitung skor setiap film kandidat berdasarkan sejumlah kriteria yang mencerminkan relevansi film terhadap preferensi pengguna. Kriteria yang digunakan meliputi rata-rata *rating*, popularitas, *recency*, dan kesesuaian genre. Model yang dibangun merupakan fungsi penilaian berbasis pembobotan (*weighted scoring*), di mana keempat kriteria tersebut digabungkan menjadi satu skor akhir melalui kombinasi linier. Proses pembangunan model dilakukan secara bertahap, dimulai dari penambahan atribut film, normalisasi atribut, perhitungan kesesuaian genre, hingga perhitungan skor akhir. Setelah skor terbentuk, rekomendasi dipilih menggunakan algoritma *greedy* dengan penerapan *diversity penalty* untuk memastikan keberagaman hasil rekomendasi.

4.4.1 Penambahan Atribut Data Kandidat Film

Setiap film kandidat diperkaya dengan atribut tambahan yang diperlukan dalam proses perhitungan skor. Pemilihan keempat atribut ini didasarkan pada pertimbangan bahwa kualitas rekomendasi tidak cukup hanya bergantung pada preferensi genre pengguna, tetapi juga perlu mempertimbangkan seberapa dikenal film tersebut secara umum, seberapa tinggi penilaian yang diterimanya, seberapa baru film tersebut dirilis, serta seberapa sesuai genre film dengan preferensi pengguna. Keempat atribut yang digunakan adalah sebagai berikut:

1. Genre

Informasi genre dipisahkan dari format aslinya yang menggunakan pemisah karakter *pipe* (|) menjadi elemen-elemen individual. Genre ini digunakan untuk menghitung nilai kesesuaian antara film kandidat dengan preferensi genre pengguna pada tahap berikutnya.

2. Popularitas

Nilai popularitas dihitung berdasarkan jumlah total *rating* yang diterima setiap film dari seluruh pengguna dalam dataset. Semakin banyak pengguna yang memberikan *rating* terhadap suatu film, semakin tinggi nilai popularitasnya. Atribut ini digunakan sebagai indikator tingkat dikenalnya suatu film di kalangan pengguna secara luas, sehingga film yang lebih dikenal memiliki peluang lebih besar untuk direkomendasikan.

3. Tahun Rilis

Tahun rilis diekstraksi dari judul film menggunakan pencocokan pola (*regular expression/regex*) terhadap angka tahun yang tercantum dalam tanda kurung. Informasi ini digunakan sebagai representasi *recency* film, dengan asumsi bahwa film yang lebih baru cenderung lebih relevan dengan selera pengguna masa kini dibandingkan film yang sudah lama dirilis.

4. Rata-rata *Rating*

Rata-rata *rating* dihitung dari seluruh *rating* yang diberikan oleh semua pengguna terhadap masing-masing film kandidat. Atribut ini mencerminkan kualitas film secara umum berdasarkan penilaian komunitas, sehingga film dengan rata-rata *rating* yang lebih tinggi dianggap lebih layak untuk direkomendasikan.

Contoh hasil penambahan data kandidat film disajikan pada Tabel 4.4.

4.4.2 Normalisasi Atribut

Sebelum digunakan dalam perhitungan skor, ketiga atribut tersebut, yakni popularitas, tahun rilis, dan rata-rata *rating* dinormalisasi menggunakan metode *min-max normalization* agar berada dalam rentang nilai yang sama, yaitu $[0, 1]$.

Normalisasi ini diperlukan karena ketiga atribut memiliki skala yang berbeda-beda, sehingga tidak dapat dibandingkan secara langsung tanpa penyesuaian terlebih dahulu. Persamaan normalisasi yang digunakan adalah sebagai berikut:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

di mana x adalah nilai asli, x_{max} dan x_{min} masing-masing adalah nilai minimum dan maksimum dari atribut yang bersangkutan, serta x' adalah nilai hasil normalisasi.

Tabel 4.4 Contoh Hasil Penambahan Data Kandidat Film User 414

<i>Title</i>	<i>Genres</i>	<i>Popularity</i>	<i>Year</i>	<i>Avg Rating</i>
Waiting to Exhale	Comedy, Drama, Romance	7	1995	2,357
Sudden Death	Action	16	1995	3,125
Dracula: Dead and Loving It	Comedy, Horror	19	1995	2,421
Balto	Adventure, Animation, Children	8	1995	3,125
Nixon	Drama	18	1995	3,833

Berbeda dengan atribut numerik, genre merupakan data kategorikal sehingga tidak dilakukan proses normalisasi. Sebagai gantinya, genre diolah dengan cara mengubahnya menjadi daftar elemen individual dan dihitung tingkat kesesuaiannya dengan preferensi pengguna melalui perhitungan *genre match score*, yang dijelaskan lebih lanjut pada subbab 4.4.3. Contoh hasil normalisasi atribut numerik disajikan pada Tabel 4.5.

Tabel 4.5 Contoh Hasil Normalisasi Atribut Kandidat Film User 414

<i>Title</i>	<i>Popularity Norm</i>	<i>Year Norm</i>	<i>Rating Norm</i>
Waiting to Exhale	0,047	0,802	0,471
Sudden Death	0,107	0,802	0,625
Dracula: Dead and Loving It	0,128	0,802	0,484
Balto	0,054	0,802	0,625
Nixon	0,121	0,802	0,767

4.4.3 Perhitungan Kesesuaian Genre

Setiap film kandidat juga dihitung nilai kesesuaian genrenya (*genre score*) terhadap preferensi pengguna. Top-3 genre diperoleh dengan menghitung frekuensi kemunculan setiap genre dari seluruh film yang telah diberi rating oleh pengguna pada data latih, kemudian diambil tiga genre dengan frekuensi tertinggi sebagai representasi preferensi pengguna. Perhitungan dilakukan dengan membandingkan genre yang dimiliki film kandidat terhadap tiga genre teratas (*top-3*) dari profil preferensi pengguna yang telah diperoleh pada tahap sebelumnya. Nilai *genre score* dihitung menggunakan persamaan berikut:

$$\text{Genre score} = \frac{|\text{Genre film} \cap \text{Genre favorit}|}{|\text{Genre favorit}|}$$

di mana *Genre film* adalah himpunan genre yang dimiliki film kandidat dan *Genre favorit* adalah himpunan tiga genre favorit pengguna. Nilai *genre score* berkisar antara 0 hingga 1, di mana nilai 1 menunjukkan bahwa seluruh genre favorit pengguna terdapat dalam film tersebut. Contoh hasil perhitungan *genre score* disajikan pada Tabel 4.6.

Tabel 4.6 Contoh Hasil Perhitungan Genre Score User 414

<i>Title</i>	<i>Genres</i>	<i>Genres Score</i>
Waiting to Exhale	Comedy, Drama, Romance	0,667
Sudden Death	Action	0,333
Dracula: Dead and Loving It	Comedy, Horror	0,333
Balto	Adventure, Animation, Children	0,000
Nixon	Drama	0,333

4.4.4 Perhitungan Skor Akhir

Skor akhir setiap film kandidat dihitung dengan menggabungkan seluruh atribut yang telah dinormalisasi, yaitu rata-rata *rating*, kesesuaian genre,

popularitas, dan *recency*. Sebelum digabungkan, nilai rata-rata *rating* terlebih dahulu dikenakan *time decay* untuk memberikan penimbangan berdasarkan usia film. Nilai *rating* yang telah mengalami *time decay* dihitung menggunakan persamaan berikut:

$$Rating\ decayed = rating\ norm \times e^{-\alpha \cdot (t_{now} - t_{film})}$$

di mana α adalah laju *decay* yang menentukan seberapa cepat pengaruh *rating* berkurang seiring bertambahnya usia film, t_{now} adalah tahun saat ini, dan t_{film} adalah tahun rilis film. Nilai α yang digunakan dalam penelitian ini adalah 0,1.

Skor akhir kemudian dihitung sebagai kombinasi linear berbobot dari keempat atribut tersebut dengan persamaan sebagai berikut:

$$Final\ score = w_g \cdot genre\ score + w_r \cdot rating\ decayed + w_p \cdot popularity\ norm + w_y \cdot year\ norm$$

di mana w_g, w_r, w_p, w_y masing-masing adalah bobot untuk kesesuaian genre, *rating* yang telah di-*decay*, popularitas, dan *recency*. Pada penelitian ini, keempat bobot ditetapkan secara merata dengan nilai masing-masing sebesar 0,25, sehingga setiap kriteria memberikan kontribusi yang setara dalam pembentukan skor akhir. Contoh hasil perhitungan skor akhir disajikan pada Tabel 4.7.

Tabel 4.7 Contoh Hasil Perhitungan Skor Akhir Kandidat Film User 414

<i>Title</i>	<i>Final Score</i>
Waiting to Exhale	0,384
Sudden Death	0,318
Dracula: Dead and Loving It	0,321
Balto	0,221
Nixon	0,323

4.4.5 Implementasi Algoritma *Greedy*

Tahapan implementasi algoritma *greedy* pada bab ini mengacu pada pseudocode yang telah dijelaskan pada Algoritma 3.1. Setelah skor akhir

diperoleh, proses pemilihan film rekomendasi dilakukan menggunakan algoritma *greedy*. Algoritma ini bekerja dengan prinsip pemilihan lokal optimal (*local optimum*) pada setiap langkah, yaitu selalu memilih film dengan skor tertinggi yang tersedia pada iterasi tersebut tanpa mempertimbangkan ulang pilihan yang telah dibuat sebelumnya. Secara umum, alur kerja algoritma *greedy* yang diterapkan adalah sebagai berikut:

1. Urutkan seluruh film kandidat berdasarkan *final score* secara menurun.
2. Pada setiap iterasi, hitung *score adjusted* untuk setiap film kandidat yang tersisa dengan mempertimbangkan *diversity penalty* terhadap film yang telah terpilih.
3. Pilih film dengan *score adjusted* tertinggi dan masukkan ke dalam daftar rekomendasi.
4. Hapus film tersebut dari daftar kandidat.
5. Ulangi langkah 2–4 hingga diperoleh sepuluh film rekomendasi.

4.4.6 Penerapan *Diversity Penalty*

Tahapan penerapan *diversity penalty* pada bab ini mengacu pada pseudocode yang telah dijelaskan pada Algoritma 2.2. Untuk meningkatkan keberagaman hasil rekomendasi, diterapkan mekanisme *diversity penalty* dalam proses pemilihan film. Pada setiap iterasi, skor film kandidat disesuaikan dengan mempertimbangkan kemiripan genrenya terhadap film-film yang telah terpilih sebelumnya. Penyesuaian skor dilakukan menggunakan persamaan berikut:

$$score\ adjusted = final\ score - \lambda \sum_{s \in S} sim(f, s)$$

di mana λ adalah parameter pengatur kekuatan penalti, S adalah himpunan film yang telah terpilih, dan $\text{sim}(f, s)$ adalah nilai kemiripan genre antara film kandidat f dengan film terpilih s , yang dihitung menggunakan persamaan berikut:

$$\text{sim}(f, s) = \frac{|\text{genre}_f \cap \text{genre}_s|}{\max(|\text{genre}_f|, 1)}$$

di mana genre_f adalah himpunan genre yang dimiliki film kandidat f dan genre_s adalah himpunan genre yang dimiliki film terpilih s . Nilai λ yang digunakan dalam penelitian ini adalah 0,3. Nilai $\lambda = 0,3$ ditetapkan sebagai nilai awal karena penalty sebesar 30% dianggap cukup signifikan untuk mempengaruhi keragaman tanpa mendominasi skor konten, sebelum kemudian divariasikan untuk menemukan konfigurasi optimal. Dengan adanya penalti ini, sistem tidak hanya memilih film dengan skor tertinggi, tetapi juga mendorong terpilihnya film dengan variasi genre yang lebih beragam sehingga hasil rekomendasi tidak bersifat monoton. Hasil akhir berupa sepuluh film rekomendasi untuk masing-masing pengguna sampel disajikan pada Tabel 4.8 hingga Tabel 4.10.

4.5 Evaluasi pada Pengguna yang Dijadikan Sampel

Tahap evaluasi bertujuan untuk menilai kualitas hasil rekomendasi yang dihasilkan oleh sistem. Evaluasi dilakukan menggunakan tiga metrik, yaitu *genre match ratio*, *Intra-List Diversity* (ILD), dan *Precision@K*. Ketiga metrik ini dipilih untuk mengukur kualitas rekomendasi dari aspek yang berbeda, yakni kesesuaian preferensi, keberagaman, dan akurasi prediksi.

Tabel 4.8 Hasil Rekomendasi Film untuk User 1

<i>Rank</i>	<i>Title</i>	<i>Genres</i>	<i>Final Score</i>
1	Deadpool (2016)	Action, Adventure, Comedy, Sci-Fi	0,609
2	Shawshank Redemption, The (1994)	Crime, Drama	0,457
3	Shrek (2001)	Adventure, Animation, Children, Comedy, Fantasy, Romance	0,530
4	Seven (a.k.a. Se7en) (1995)	Mystery, Thriller	0,369
5	Won't You Be My Neighbor? (2018)	Documentary	0,363
6	The Magnificent Seven (2016)	Action, Western	0,400
7	Get Out (2017)	Horror	0,334
8	Tom Segura: Disgraceful (2018)	Comedy	0,435
9	Lord of the Rings: The Fellowship of the Ring, The (2001)	Adventure, Fantasy	0,470
10	Interstellar (2014)	Sci-Fi, IMAX	0,359

Tabel 4.9 Hasil Rekomendasi Film untuk User 414

<i>Rank</i>	<i>Title</i>	<i>Genres</i>	<i>Final Score</i>
1	CHiPS (2017)	Action, Comedy Drama	0,580
2	Inception (2010)	Action, Crime, Drama, Mystery, Sci-Fi, Thriller, IMAX	0,553
3	Shrek (2001)	Adventure, Animation, Children, Comedy, Fantasy, Romance	0,447
4	Shawshank Redemption, The (1994)	Crime, Drama	0,541
5	Won't You Be My Neighbor? (2018)	Documentary	0,363
6	Get Out (2017)	Horror	0,334
7	The Hateful Eight (2015)	Western	0,320
8	Terminator 2: Judgment Day (1991)	Action, Sci-Fi	0,458
9	Miss Sloane (2016)	Thriller	0,330
10	Lord of the Rings: The Fellowship of the Ring, The (2001)	Adventure, Fantasy	0,386

Tabel 4.10 Hasil Rekomendasi Film untuk User 610

<i>Rank</i>	<i>Title</i>	<i>Genres</i>	<i>Final Score</i>
1	Fight Club (1999)	Action, Crime, Drama, Thriller	0,645
2	Inception (2010)	Action, Crime, Drama, Mystery, Sci-Fi, Thriller, IMAX	0,637
3	Lord of the Rings: The Fellowship of the Ring, The (2001)	Adventure, Fantasy	0,386
4	Schindler's List (1993)	Drama, War	0,461
5	Won't You Be My Neighbor? (2018)	Documentary	0,363
6	Mamma Mia: Here We Go Again! (2018)	Comedy, Romance	0,352
7	Get Out (2017)	Horror	0,334
8	Piper (2016)	Animation	0,330
9	The Hateful Eight (2015)	Western	0,320
10	Terminator 2: Judgment Day (1991)	Action, Sci-Fi	0,458

4.6 Evaluasi pada Pengguna yang Dijadikan Sampel

Tahap evaluasi bertujuan untuk menilai kualitas hasil rekomendasi yang dihasilkan oleh sistem. Evaluasi dilakukan menggunakan tiga metrik, yaitu *genre match ratio*, *Intra-List Diversity* (ILD), dan *Precision@K*. Ketiga metrik ini dipilih untuk mengukur kualitas rekomendasi dari aspek yang berbeda, yakni kesesuaian preferensi, keberagaman, dan akurasi prediksi.

4.5.1 Genre Match Ratio

Genre match ratio mengukur persentase film rekomendasi yang mengandung setidaknya satu genre dari tiga genre favorit pengguna (*top-3*). Penggunaan *top-3* genre dipilih untuk menjaga konsistensi dengan perhitungan *genre score* pada tahap 4.4.3, sekaligus memastikan bahwa metrik yang digunakan cukup ketat dalam menilai kesesuaian preferensi. Genre favorit pengguna ditentukan berdasarkan frekuensi genre pada data latih, kemudian setiap

film rekomendasi diperiksa apakah memuat salah satu genre tersebut. Nilai *genre match ratio* dihitung menggunakan persamaan berikut:

$$\text{Genre match ratio} = \frac{N}{K} \times 100\%$$

di mana N adalah jumlah film rekomendasi yang memuat setidaknya satu genre favorit pengguna dan K adalah jumlah total film rekomendasi. Nilai yang lebih tinggi menunjukkan bahwa rekomendasi yang dihasilkan lebih sesuai dengan preferensi genre pengguna. Hasil *genre match ratio* untuk ketiga pengguna yang dijadikan sampel disajikan pada Tabel 4.11

Tabel 4.11 Hasil Genre Match Ratio Ketiga User

User ID	Top-3 Genre Favorit	Genre Match Ratio
1	Action, Drama, Thriller	40%
414	Drama, Comedy, Action	50%
610	Action, Drama, Thriller	50%

4.5.2 Intra-List Diversity (ILD)

Intra-List Diversity (ILD) mengukur tingkat keberagaman daftar rekomendasi dengan menghitung rata-rata jarak antar pasangan film yang direkomendasikan. Setiap pasangan film dalam daftar rekomendasi, misalnya film ke-1 dengan film ke-2, film ke-1 dengan film ke-3, dan seterusnya, dihitung jarak genrenya menggunakan *Jaccard distance*. Seluruh nilai jarak tersebut kemudian dirata-rata sehingga diperoleh satu nilai yang merepresentasikan tingkat keberagaman keseluruhan daftar rekomendasi. Jarak antar film dihitung menggunakan persamaan berikut:

$$\text{Jaccard distance}(f_i, f_j) = 1 - \frac{|genre_{f_i} \cap genre_{f_j}|}{|genre_{f_i} \cup genre_{f_j}|}$$

di mana f_i adalah film ke- i dan f_j adalah film ke- j dalam daftar rekomendasi, dengan $i \neq j$. Nilai ILD kemudian dihitung sebagai rata-rata *Jaccard distance* dari seluruh pasangan film:

$$ILD = \frac{2}{K(K-1)} \sum_{i=1}^K \sum_{j=i+1}^K Jaccard\ distance(f_i, f_j)$$

di mana K adalah jumlah total film rekomendasi, $\frac{2}{K(K-1)}$ adalah faktor normalisasi yang mewakili jumlah seluruh pasangan film yang mungkin. Penjumlahan dilakukan terhadap seluruh kombinasi pasangan film (i, j) dengan $i < j$, sehingga setiap pasangan hanya dihitung satu kali. Nilai ILD berkisar antara 0 hingga 1, di mana nilai yang mendekati 1 menunjukkan bahwa film-film yang direkomendasikan memiliki keberagaman genre yang tinggi. Hasil ILD untuk ketiga pengguna yang dijadikan sampel disajikan pada Tabel 4.12.

Tabel 4.12 Hasil Intra-List Diversity (ILD) Ketiga User

User ID	ILD
1	0,969
414	0,949
610	0,951

4.5.3 Precision@K

Precision@K mengukur seberapa banyak film dalam daftar rekomendasi yang benar-benar relevan bagi pengguna, di mana relevansi ditentukan berdasarkan kecocokan dengan data uji. Film rekomendasi dianggap relevan apabila *movieId*-nya terdapat dalam data uji pengguna, yang merepresentasikan film-film yang memang ditonton oleh pengguna pada periode berikutnya. Nilai *Precision@K* dihitung menggunakan persamaan berikut:

$$Precision@K = \frac{|rekomendasi \cap data\ uji|}{K}$$

di mana K adalah jumlah film rekomendasi yang dihasilkan, yaitu 10. Nilai $Precision@K$ berkisar antara 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan bahwa sistem lebih mampu memprediksi film yang relevan bagi pengguna. Hasil $Precision@K$ untuk ketiga pengguna yang dijadikan sampel disajikan pada Tabel 4.13.

Tabel 4.13 Hasil $Precision@K$ Ketiga User

User ID	Jumlah Film Data Uji	Film Rekomendasi yang Cocok	$Precision@K$
1	261	1	0,1
414	538	7	0,7
610	261	1	0,1

4.5.4 Rekapitulasi Hasil Evaluasi

Hasil evaluasi dari ketiga metrik untuk seluruh pengguna sampel dirangkum pada Tabel 4.14. Rekapitulasi ini digunakan sebagai dasar dalam menganalisis kekuatan dan keterbatasan sistem rekomendasi yang telah dibangun.

Tabel 4.14 Rekapitulasi Hasil Evaluasi Ketiga User

User ID	<i>Genre Match Ratio</i>	ILD	$Precision@K$
1	40%	0,969	0,1
414	50%	0,949	0,7
610	50%	0,951	0,1

4.7 Evaluasi Keseluruhan Sistem

Selain evaluasi pada pengguna sampel, sistem juga diuji terhadap seluruh pengguna yang terdapat dalam dataset menggunakan pendekatan *all candidate*, di mana seluruh film yang belum pernah ditonton oleh pengguna dijadikan ruang kandidat tanpa pembatasan genre. Pengujian dilakukan terhadap 610 pengguna dengan pembagian data latih dan data uji menggunakan proporsi 80:20 untuk setiap pengguna.

4.6.1 Hasil Evaluasi Keseluruhan

Hasil evaluasi rata-rata dari seluruh pengguna disajikan pada Tabel 4.15.

Tabel 4.15 Hasil Evaluasi Keseluruhan Sistem All Candidate

Metrik	Nilai Rata-rata	Nilai Minimum	Nilai Maksimum
<i>Genre Match Ratio</i>	36,68%	0,00%	70,00%
ILD	0,984	0,946	0,998
<i>Precision@K</i>	0,028	0,000	0,600

4.6.2 Analisis Hasil Evaluasi

Berdasarkan hasil evaluasi keseluruhan, analisis dilakukan untuk memperoleh pemahaman lebih lanjut mengenai kinerja sistem rekomendasi.

1. *Genre Match Ratio*

Rata-rata *genre match ratio* sebesar 36,68% menunjukkan bahwa dengan pendekatan *all candidate*, sistem tidak selalu menghasilkan rekomendasi yang sepenuhnya sesuai dengan top-3 genre favorit pengguna. Hal ini disebabkan oleh ruang kandidat yang sangat luas, sehingga sistem memiliki kebebasan dalam memilih film berdasarkan kombinasi seluruh kriteria, tidak hanya genre. Nilai minimum sebesar 0% terjadi pada pengguna dengan preferensi genre yang sangat spesifik, sementara nilai maksimum sebesar 70% menunjukkan bahwa sistem masih mampu memberikan rekomendasi yang cukup relevan secara genre pada kondisi tertentu.

2. ILD

Nilai ILD rata-rata sebesar 0,984 menunjukkan bahwa sistem menghasilkan rekomendasi dengan tingkat keberagaman yang sangat tinggi. Rentang nilai yang relatif sempit antara 0,946 hingga 0,998 mengindikasikan bahwa mekanisme *diversity penalty* bekerja secara konsisten pada seluruh pengguna, mendorong terpilihnya film-film dengan variasi genre yang beragam. Hal ini menunjukkan bahwa pendekatan *all candidate*

memberikan ruang eksplorasi yang luas bagi sistem dalam memilih film dengan variasi genre yang beragam.

3. Precision@K

Nilai *Precision@K* rata-rata sebesar 0,028 menunjukkan bahwa tingkat kecocokan antara rekomendasi dan data uji relatif rendah. Namun kondisi ini merupakan karakteristik umum pada sistem rekomendasi dengan ruang kandidat yang sangat besar. Sistem rekomendasi dalam penelitian ini cenderung memilih film berdasarkan karakteristik atribut film, seperti genre, *rating*, popularitas, dan *recency*, sehingga rekomendasi yang dihasilkan tidak selalu muncul pada data uji yang bersifat terbatas. Oleh karena itu, rendahnya nilai *precision* tidak selalu menunjukkan kinerja sistem yang buruk, tetapi lebih disebabkan oleh keterbatasan data uji yang belum sepenuhnya mencerminkan preferensi pengguna. Nilai maksimum sebesar 0,6 menunjukkan bahwa pada beberapa pengguna, sistem masih mampu menghasilkan rekomendasi yang cukup akurat.

Secara keseluruhan, hasil evaluasi menunjukkan adanya *trade-off* antara keberagaman dan kesesuaian rekomendasi. Pendekatan *all candidate* cenderung menghasilkan rekomendasi yang sangat beragam, namun dengan tingkat kesesuaian dan akurasi yang lebih rendah. Hal ini menjadi dasar untuk melakukan eksperimen lebih lanjut pada tahap berikutnya dengan membatasi ruang kandidat serta menyesuaikan parameter model.

4.8 Analisis Hasil Rekomendasi

Analisis hasil rekomendasi dilakukan terhadap sepuluh film teratas (*top-10 recommendation*) yang dihasilkan oleh sistem untuk memahami karakteristik

rekomendasi yang diberikan kepada pengguna. Analisis ini dilakukan terhadap seluruh pengguna dalam dataset, sehingga hasil yang diperoleh bersifat representatif dalam menggambarkan karakteristik sistem rekomendasi secara keseluruhan.

Analisis mencakup aspek kesesuaian genre, tingkat keberagaman, variasi genre, proporsi film baru, serta karakteristik umum dari hasil rekomendasi yang dihasilkan menggunakan pendekatan *all candidate*.

4.7.1 Analisis Genre Dominan

Berdasarkan hasil rekomendasi yang dihasilkan, sistem menunjukkan kecenderungan untuk tetap mempertimbangkan preferensi genre pengguna, meskipun tidak secara dominan. Hal ini terlihat dari nilai *genre match ratio* yang tidak terlalu tinggi, yang menunjukkan bahwa tidak semua film dalam daftar rekomendasi berasal dari genre favorit pengguna.

Pendekatan *all candidate* memberikan kebebasan bagi sistem untuk memilih film dari berbagai genre, sehingga rekomendasi tidak hanya terfokus pada genre tertentu. Akibatnya, meskipun preferensi pengguna tetap menjadi salah satu pertimbangan, hasil rekomendasi cenderung lebih bervariasi dan tidak sepenuhnya didominasi oleh genre favorit.

4.7.2 Analisis Tingkat Diversitas Rekomendasi

Tingkat keberagaman rekomendasi yang dihasilkan tergolong sangat tinggi, sebagaimana ditunjukkan oleh nilai ILD yang mendekati 1. Hal ini menunjukkan bahwa film-film dalam daftar rekomendasi memiliki perbedaan genre yang signifikan satu sama lain.

Keberagaman ini dipengaruhi oleh dua faktor utama, yaitu luasnya ruang kandidat pada pendekatan *all candidate* serta penerapan *diversity penalty* dalam algoritma *greedy*. Kombinasi kedua faktor tersebut mendorong sistem untuk memilih film yang tidak hanya memiliki skor tinggi, tetapi juga berbeda dari film yang telah dipilih sebelumnya.

4.7.3 Analisis Variasi Genre

Variasi genre dalam daftar rekomendasi menunjukkan bahwa sistem mampu menghadirkan kombinasi genre yang beragam dalam satu daftar rekomendasi. Hal ini mencerminkan kemampuan sistem dalam menyeimbangkan antara eksplorasi (menyajikan genre yang berbeda) dan eksploitasi (memanfaatkan preferensi pengguna).

Namun, pada beberapa pengguna dengan preferensi yang sangat spesifik, variasi genre cenderung sedikit menurun karena sistem tetap memberikan bobot pada kesesuaian genre.

4.7.4 Analisis Proporsi Film Baru (*Recency*)

Berdasarkan nilai *recency*, sistem cenderung merekomendasikan kombinasi antara film lama dan film yang relatif baru. Hal ini menunjukkan bahwa fitur *recency* berperan dalam menjaga keseimbangan temporal dalam rekomendasi.

Film yang lebih baru cenderung memiliki nilai *recency* yang tinggi, sehingga memiliki peluang lebih besar untuk dipilih. Namun, film lama dengan *rating* tinggi atau popularitas tinggi tetap dapat masuk dalam daftar rekomendasi, sehingga sistem tidak sepenuhnya bias terhadap film terbaru.

4.7.5 Karakteristik Umum Hasil Rekomendasi

Secara keseluruhan, hasil rekomendasi yang dihasilkan oleh sistem memiliki beberapa karakteristik utama, yaitu:

1. Tidak sepenuhnya terfokus pada genre favorit pengguna.
2. Memiliki tingkat keberagaman yang sangat tinggi.
3. Menampilkan variasi genre yang cukup luas dalam satu daftar rekomendasi.
4. Mengandung kombinasi antara film lama dan film baru.
5. Menunjukkan keseimbangan antara berbagai kriteria yang digunakan dalam perhitungan skor.

Karakteristik ini menunjukkan bahwa sistem rekomendasi yang dibangun lebih menekankan pada keberagaman dan eksplorasi dibandingkan dengan kesesuaian yang ketat terhadap preferensi pengguna.

Hasil analisis ini menunjukkan bahwa pendekatan *all candidate* menghasilkan rekomendasi yang sangat beragam namun kurang optimal dalam hal kesesuaian dan akurasi. Oleh karena itu, diperlukan eksperimen lebih lanjut dengan melakukan pembatasan ruang kandidat serta penyesuaian parameter model untuk meningkatkan kualitas rekomendasi yang dihasilkan.

4.9 Eksperimen dan Analisis Hasil Eksperimen

Pada tahap ini dilakukan serangkaian eksperimen untuk menguji pengaruh variasi metode dan parameter terhadap kualitas rekomendasi yang dihasilkan. Eksperimen bertujuan untuk memahami bagaimana perubahan ruang kandidat, bobot kriteria, serta parameter *diversity penalty* memengaruhi kesesuaian, keberagaman, dan akurasi rekomendasi. Eksperimen dilakukan terhadap seluruh

610 pengguna dalam dataset dan hasilnya dievaluasi menggunakan tiga metrik utama, yaitu *genre match ratio*, ILD, dan *Precision@K*.

4.8.1 Eksperimen Ruang Kandidat

Eksperimen pertama bertujuan untuk membandingkan pengaruh pendekatan ruang kandidat terhadap kualitas rekomendasi. Dua pendekatan yang dibandingkan adalah *all candidate*, di mana seluruh film yang belum ditonton dijadikan kandidat, dan *genre filtering* dengan tiga variasi pembatasan berdasarkan top-3, top-2, dan top-1 genre favorit pengguna. Pembatasan ini dilakukan dengan hanya menyertakan film yang mengandung setidaknya satu genre dari sejumlah genre favorit pengguna yang ditentukan. Hasil rata-rata dari seluruh pengguna disajikan pada Tabel 4.16.

Tabel 4.16 Perbandingan Hasil Evaluasi Pendekatan Ruang Kandidat

Pendekatan	<i>Candidate Size</i>	<i>Genre Match Ratio</i>	ILD	<i>Precision@K</i>
All Candidate	9.610	36,74%	0,984	0,028
3 Genre	6.358	100,00%	0,887	0,050
2 Genre	5.203	100,00%	0,854	0,045
1 Genre	3.286	100,00%	0,774	0,039

Hasil eksperimen menunjukkan adanya *trade-off* yang jelas antara kesesuaian genre dan keberagaman rekomendasi. Pendekatan *all candidate* menghasilkan nilai ILD tertinggi (0,984), namun *genre match ratio*-nya hanya 36,74% karena sistem bebas memilih film dari seluruh ruang kandidat tanpa mempertimbangkan genre secara eksklusif. Sebaliknya, ketiga pendekatan *genre filtering* menghasilkan *genre match ratio* yang mendekati 100%, karena seluruh kandidat dijamin memuat setidaknya satu genre favorit pengguna. Namun, pembatasan ruang kandidat ini menyebabkan penurunan nilai ILD. Semakin ketat

pembatasan genre, semakin kecil ruang kandidat dan semakin rendah keberagaman yang dapat dihasilkan.

Menariknya, pendekatan 3 genre menghasilkan *Precision@K* tertinggi (0,050) dibandingkan pendekatan lainnya, menunjukkan bahwa pembatasan kandidat yang moderat justru meningkatkan kemampuan sistem dalam memprediksi film yang relevan. Namun ketika pembatasan terlalu ketat (1 genre), *precision* justru menurun karena ruang kandidat menjadi terlalu sempit sehingga mengurangi kemungkinan film yang relevan masuk dalam daftar kandidat.

Berdasarkan hasil eksperimen ini, pendekatan *all candidate* dipilih sebagai pendekatan utama dalam penelitian ini karena menghasilkan keberagaman tertinggi dan memberikan fleksibilitas yang lebih besar bagi sistem. Secara umum, pendekatan *all candidate* lebih cocok untuk pengguna dengan preferensi genre yang luas dan beragam, sedangkan pendekatan *genre filtering* lebih efektif untuk pengguna dengan preferensi yang lebih spesifik dan konsisten. Sehingga kedua pendekatan ini pada dasarnya saling melengkapi dan dapat dipilih sesuai dengan karakteristik pengguna yang dilayani.

4.8.2 Eksperimen Bobot Kriteria

Eksperimen kedua bertujuan untuk menganalisis pengaruh variasi bobot pada keempat kriteria, yakni genre, *rating*, popularitas, dan *recency* terhadap kualitas rekomendasi. Bobot pada masing-masing kriteria divariasikan sehingga totalnya tetap bernilai 1, dan setiap konfigurasi dievaluasi menggunakan *Precision@K* dan ILD terhadap seluruh pengguna dalam dataset. Sebelas konfigurasi bobot diuji sebagaimana disajikan pada Tabel 4.17.

Tabel 4.17 Hasil Eksperimen Variasi Bobot Kriteria

Eksperimen	Genre	Rating	Popularity	Recency	Precision@K	ILD
E1	0,25	0,25	0,25	0,25	0,027	0,984
E2	0,50	0,20	0,15	0,15	0,030	0,935
E3	0,20	0,50	0,15	0,15	0,013	0,975
E4	0,20	0,20	0,50	0,10	0,074	0,928
E5	0,20	0,20	0,10	0,50	0,007	0,981
E6	0,35	0,35	0,15	0,15	0,023	0,961
E7	0,40	0,30	0,20	0,10	0,040	0,950
E8	0,30	0,40	0,20	0,10	0,036	0,966
E9	0,30	0,20	0,40	0,10	0,071	0,934
E10	0,30	0,20	0,10	0,40	0,005	0,970
E11	0,40	0,25	0,20	0,15	0,040	0,949

Berdasarkan hasil eksperimen, terlihat bahwa kriteria *popularity* memiliki pengaruh terbesar terhadap *Precision@K*. Konfigurasi E4 yang memberikan bobot tertinggi pada popularitas (0,50) menghasilkan *Precision@K* tertinggi sebesar 0,074, meskipun dengan konsekuensi penurunan ILD menjadi 0,928. Hal ini mengindikasikan bahwa film-film yang populer, yakni yang banyak ditonton dan diberi *rating* oleh pengguna lain, cenderung lebih relevan secara umum dan memiliki peluang lebih besar untuk muncul dalam data uji pengguna.

Sebaliknya, konfigurasi E5 yang memberikan bobot tertinggi pada *recency* (0,50) menghasilkan ILD sebesar (0,981) namun nilai *Precision@K* (0,007). Hal ini menunjukkan bahwa penekanan berlebihan pada *recency* mendorong sistem untuk terlalu banyak merekomendasikan film baru yang mungkin belum banyak dikenal atau ditonton oleh pengguna. Konfigurasi E3 yang memberikan bobot tinggi pada *rating* (0,50) juga menghasilkan *precision* yang rendah (0,013), mengindikasikan bahwa kualitas film berdasarkan penilaian komunitas tidak selalu berkorelasi langsung dengan relevansi terhadap preferensi pengguna tertentu.

Konfigurasi E7 dengan bobot genre (0,40) dan *rating* (0,30) yang menghasilkan *precision* (0,040) dan ILD (0,950). Konfigurasi ini tidak menghasilkan nilai tertinggi pada salah satu metrik, namun performanya relatif stabil di kedua aspek. Berdasarkan hasil ini, E4, E7, dan E5 dipilih sebagai representasi konfigurasi dengan performa terbaik, sedang, dan terburuk untuk digunakan dalam eksperimen parameter lambda selanjutnya, guna mengeksplorasi bagaimana pengaruh λ bervariasi di bawah kondisi bobot yang berbeda.

4.8.3 Eksperimen Parameter Lambda

Eksperimen ketiga ini bertujuan untuk menganalisis pengaruh nilai parameter lambda (λ) terhadap kualitas rekomendasi. Parameter λ mengatur kekuatan *diversity penalty* dalam algoritma *greedy*. Semakin besar nilainya, semakin besar penalti yang diberikan terhadap film dengan genre yang mirip dengan film yang telah terpilih sebelumnya. Eksperimen dilakukan dengan memvariasikan nilai λ dari 0 hingga 0,5 pada ketiga konfigurasi bobot terpilih dari eksperimen sebelumnya, yaitu E4 (terbaik), E7 (sedang), dan E5 (terburuk). Hasil eksperimen disajikan pada Tabel 4.18.

Hasil eksperimen menunjukkan pola yang konsisten yakni semakin besar nilai λ , semakin tinggi nilai ILD yang dihasilkan di seluruh konfigurasi bobot. Pada $\lambda = 0$ (tanpa *diversity penalty*), nilai ILD pada ketiga konfigurasi masih berada di bawah 0,80, yang menunjukkan bahwa tanpa penalti keberagaman, sistem cenderung memilih film-film dengan genre yang relatif serupa. Peningkatan λ secara bertahap mendorong sistem untuk memilih film yang lebih

beragam secara genre, sehingga nilai ILD meningkat secara konsisten di seluruh konfigurasi.

Tabel 4.18 Hasil Eksperimen Variasi Parameter Lambda

Eksperimen	λ	Bobot	Precision	ILD
E12	0,00	E4	0,080	0,752
E13	0,00	E7	0,032	0,487
E14	0,00	E5	0,013	0,524
E15	0,05	E4	0,082	0,833
E16	0,05	E7	0,045	0,685
E17	0,05	E5	0,007	0,835
E18	0,10	E4	0,056	0,788
E19	0,10	E7	0,005	0,920
E20	0,10	E5	0,078	0,900
E21	0,20	E4	0,046	0,914
E22	0,20	E7	0,004	0,966
E23	0,20	E5	0,074	0,928
E24	0,30	E4	0,040	0,950
E25	0,30	E7	0,007	0,981
E26	0,30	E5	0,007	0,981
E27	0,40	E4	0,068	0,948
E28	0,40	E7	0,037	0,967
E29	0,40	E5	0,005	0,986
E30	0,50	E4	0,063	0,966
E31	0,50	E7	0,035	0,980
E32	0,50	E5	0,004	0,993

Hubungan antara λ dan $Precision@K$ bersifat lebih kompleks dan tidak linear. Pada konfigurasi E4, nilai *precision* tertinggi dicapai $\lambda = 0,05$ (E15, *precision* = 0,082), bukan pada $\lambda = 0$. Hal ini mengindikasikan bahwa sejumlah kecil *diversity penalty* justru membantu sistem menghindari rekomendasi yang terlalu homogen, sehingga menghasilkan daftar rekomendasi yang lebih relevan bagi pengguna. Setelah melewati titik optimal tersebut, peningkatan λ lebih lanjut cenderung menurunkan *precision* karena sistem mulai terlalu menekankan keberagaman hingga mengabaikan relevansi.

Selanjutnya dilakukan eksperimen tambahan dengan konfigurasi bobot yang lebih ekstrem untuk mengeksplorasi kemungkinan memperoleh nilai *precision* yang lebih tinggi melalui penekanan yang lebih kuat pada kriteria genre. Hasil eksperimen ini disajikan pada Tabel 4.19.

Tabel 4.19 Hasil Eksperimen Lambda dengan Konfigurasi Bobot Ekstrem

Eksperimen	λ	Genre	Rating	Popularitas	Recency	Precision@K	ILD
E33	0,00	0,55	0,20	0,15	0,10	0,021	0,396
E34	0,05	0,55	0,20	0,15	0,10	0,027	0,554
E35	0,10	0,55	0,20	0,15	0,10	0,036	0,677
E36	0,20	0,55	0,20	0,15	0,10	0,037	0,867
E37	0,30	0,55	0,20	0,15	0,10	0,034	0,925
E38	0,40	0,55	0,20	0,15	0,10	0,029	0,953
E39	0,50	0,55	0,20	0,15	0,10	0,027	0,966
E40	0,00	0,70	0,10	0,15	0,05	0,022	0,378
E41	0,05	0,70	0,10	0,15	0,05	0,021	0,495
E42	0,10	0,70	0,10	0,15	0,05	0,029	0,598
E43	0,20	0,70	0,10	0,15	0,05	0,041	0,789
E44	0,30	0,70	0,10	0,15	0,05	0,038	0,888
E45	0,40	0,70	0,10	0,15	0,05	0,031	0,928
E46	0,50	0,70	0,10	0,15	0,05	0,030	0,953

Berdasarkan hasil eksperimen, terdapat pola yang konsisten antara nilai λ dan kedua metrik evaluasi yang digunakan. Nilai *Precision@K* cenderung optimal pada λ yang kecil, dengan nilai tertinggi dicapai oleh konfigurasi E15 ($\lambda = 0,05$, bobot E4) sebesar 0,082. Hal ini menunjukkan bahwa penalti keberagaman yang terlalu besar dapat memaksa sistem menyimpang dari kandidat film yang paling relevan secara prediktif, sehingga menurunkan akurasi rekomendasi. Sebaliknya, nilai ILD meningkat seiring dengan besarnya λ , dengan nilai tertinggi dicapai oleh konfigurasi E32 ($\lambda = 0,50$, bobot E5) sebesar 0,993. Semakin besar penalti

keberagaman yang diterapkan, semakin beragam genre film yang dipilih oleh sistem, meskipun hal ini berpotensi mengorbankan relevansi prediktif.

Temuan ini mengindikasikan adanya *trade-off* inheren antara *Precision@K* dan ILD dalam sistem rekomendasi yang dibangun. Apabila prioritas utama adalah relevansi rekomendasi terhadap preferensi pengguna, konfigurasi E15 dengan $\lambda = 0,05$ dan bobot E4 (popularitas=0,50, genre=0,20, rating=0,20, recency=0,10) merupakan pilihan yang paling sesuai. Sebaliknya, apabila prioritas utama adalah keberagaman rekomendasi untuk mendorong eksplorasi konten, konfigurasi dengan λ yang lebih besar seperti E32 dengan $\lambda = 0,50$ dan bobot E5 (popularitas=0,10, genre=0,20, rating=0,20, recency=0,50) memberikan nilai ILD yang jauh lebih tinggi. Dengan demikian, pemilihan konfigurasi optimal bergantung pada kebutuhan spesifik pengguna: sistem yang mengutamakan akurasi prediksi sebaiknya menggunakan $\lambda=0,05$, sedangkan sistem yang mengutamakan keberagaman rekomendasi sebaiknya menggunakan $\lambda=0,50$.

4.8.4 Analisis dan Keputusan Konfigurasi

Berdasarkan seluruh eksperimen yang telah dilakukan, terdapat beberapa temuan utama yang dapat dirumuskan. Pertama, terdapat *trade-off* yang inheren antara kesesuaian genre, keberagaman, dan akurasi prediksi. Peningkatan pada salah satu aspek umumnya disertai penurunan pada aspek lainnya. Kedua, popularitas merupakan kriteria yang paling berpengaruh terhadap *Precision@K*, sementara *recency* memiliki pengaruh terbesar terhadap ILD namun berdampak negatif terhadap akurasi. Ketiga, parameter λ secara konsisten meningkatkan keberagaman rekomendasi, dan terdapat titik optimal di mana sejumlah kecil *diversity penalty* justru turut meningkatkan *precision* sebelum akhirnya menurun

seiring peningkatan λ lebih lanjut. Keempat, peningkatan bobot genre secara ekstrem tidak terbukti meningkatkan akurasi secara signifikan, melainkan justru menghasilkan rekomendasi yang lebih homogen ketika tidak dikombinasikan dengan *diversity penalty* yang memadai.

Berdasarkan temuan-temuan tersebut, nilai *Precision@K* tertinggi sebesar 0,082 dicapai oleh konfigurasi E15 dengan $\lambda = 0,05$ dan bobot popularitas=0,50, genre=0,20, rating=0,20, serta recency=0,10. Sementara itu, nilai ILD tertinggi sebesar 0,993 dicapai oleh konfigurasi E32 dengan $\lambda = 0,50$ dan bobot genre=0,55, rating=0,20, popularitas=0,15, serta recency=0,10. Dengan demikian, pemilihan konfigurasi optimal bergantung pada kebutuhan spesifik pengguna: sistem yang mengutamakan akurasi prediksi sebaiknya menggunakan $\lambda=0,05$, sedangkan sistem yang mengutamakan keberagaman rekomendasi sebaiknya menggunakan $\lambda=0,50$.

4.10 Integrasi Nilai Islam dalam Sistem Rekomendasi

Islam mengajarkan pentingnya selektivitas dalam mengonsumsi sesuatu, termasuk konten hiburan. Hal ini sejalan dengan firman Allah SWT dalam Al-Qur'an Surah Al-Isra' ayat 36 (Kemenag, 2022), yang artinya:

"Dan janganlah kamu mengikuti sesuatu yang tidak kamu ketahui. Karena pendengaran, penglihatan, dan hati nurani, semua itu akan diminta pertanggungjawabannya."

Ayat tersebut mengandung pesan bahwa setiap individu bertanggung jawab atas apa yang dilihat, didengar, dan dirasakan, termasuk konten yang dikonsumsi melalui media hiburan. Dalam konteks sistem rekomendasi, hal ini bermakna bahwa sistem seharusnya tidak hanya mempertimbangkan preferensi dan

popularitas, tetapi juga memberikan ruang bagi pengguna untuk menentukan batasan konten yang sesuai dengan nilai dan keyakinannya.

4.9.1 Pendekatan Filter Konten

Integrasi nilai Islam dalam penelitian ini dapat diwujudkan melalui pendekatan *parental control* atau filter konten yang bersifat opsional dan dapat diaktifkan sesuai permintaan pengguna. Pendekatan ini dipilih karena beberapa alasan. Pertama, penetapan konten yang layak atau tidak layak secara absolut dalam konteks film merupakan ranah ijtihad yang bersifat subjektif dan bergantung pada konteks, sehingga tidak tepat untuk dijadikan keputusan sistem secara sepihak. Kedua, memberikan kontrol kepada pengguna lebih sesuai dengan prinsip Islam tentang tanggung jawab individu atas pilihan yang dibuat. Ketiga, pendekatan ini menjaga objektivitas penelitian sekaligus tetap mengakomodasi kebutuhan pengguna yang ingin membatasi konten berdasarkan nilai keislaman.

4.9.2 Rancangan Mekanisme Filter Konten

Dalam rancangan sistem rekomendasi yang dikembangkan, mekanisme filter konten dapat diimplementasikan sebagai lapisan tambahan (*optional layer*) sebelum proses pemilihan kandidat film. Pengguna dapat memilih untuk mengaktifkan filter berdasarkan kategori konten tertentu, misalnya berdasarkan rating usia (*age rating*) seperti G, PG, atau PG-13, atau berdasarkan genre tertentu yang dianggap tidak sesuai. Dengan demikian, ruang kandidat yang terbentuk sudah menyesuaikan dengan preferensi konten pengguna sebelum memasuki tahap perhitungan skor dan pemilihan rekomendasi.

Pendekatan ini sejalan dengan konsep *ikhtiyar* dalam Islam, yakni kebebasan memilih yang disertai tanggung jawab, di mana sistem menyediakan

sarana, namun keputusan akhir tetap berada di tangan pengguna. Sistem tidak memaksakan definisi konten yang layak, melainkan memfasilitasi pengguna untuk menentukan sendiri batasan yang sesuai dengan nilai dan kebutuhannya.

4.9.3 Relevansi dengan Tujuan Penelitian

Integrasi nilai Islam dalam penelitian ini bukan merupakan bagian dari eksperimen utama, melainkan merupakan refleksi terhadap implikasi praktis dari sistem yang dibangun. Sistem rekomendasi yang baik tidak hanya optimal secara teknis, tetapi juga bertanggung jawab secara sosial dan etis. Dengan menyediakan mekanisme filter konten yang dapat dikustomisasi, sistem rekomendasi yang dikembangkan dalam penelitian ini berpotensi untuk dimanfaatkan secara lebih luas oleh pengguna yang ingin menikmati rekomendasi film sambil tetap menjaga batasan konten sesuai dengan nilai keislaman yang diyakininya.

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat ditarik kesimpulan bahwa sistem rekomendasi film multi-kriteria berbasis algoritma *greedy* dengan *diversity penalty* berhasil dirancang dan diimplementasikan. Sistem ini menggabungkan empat kriteria dalam perhitungan skor, yaitu kesesuaian genre (*genre match score*), rata-rata *rating* yang dikenakan *time decay*, popularitas, dan *recency*, dengan bobot masing-masing yang dapat dikonfigurasi sesuai kebutuhan. Algoritma *greedy* digunakan untuk memilih film secara bertahap, dan mekanisme *diversity penalty* dengan parameter lambda (λ) diterapkan untuk mendorong keberagaman dalam daftar rekomendasi dengan memberikan penalti terhadap film yang memiliki kemiripan genre tinggi dengan film yang telah terpilih sebelumnya. Hasil evaluasi terhadap seluruh 610 pengguna dalam dataset menunjukkan bahwa sistem mampu menghasilkan daftar rekomendasi yang beragam dengan rata-rata ILD sebesar 0,984, serta mampu memprediksi film yang relevan bagi pengguna sebagaimana ditunjukkan oleh nilai rata-rata *Precision@K* sebesar 0,028.

Eksperimen terhadap variasi bobot kriteria dan parameter lambda menunjukkan bahwa peningkatan bobot pada kriteria popularitas terbukti paling efektif dalam meningkatkan *Precision@K*, sementara peningkatan nilai lambda secara konsisten meningkatkan ILD di seluruh konfigurasi yang diuji. Ditemukan pula bahwa sejumlah kecil *diversity penalty* ($\lambda=0,05$) justru turut meningkatkan akurasi sebelum akhirnya menurun seiring peningkatan lambda lebih lanjut. Nilai *Precision@K* tertinggi sebesar 0,082 dicapai pada konfigurasi dengan bobot

popularitas=0,50, genre=0,20, rating=0,20, recency=0,10, dan $\lambda=0,05$, sedangkan nilai ILD tertinggi sebesar 0,993 dicapai pada konfigurasi dengan bobot genre=0,55, rating=0,20, popularitas=0,15, recency=0,10, dan $\lambda=0,50$. Dengan demikian, pemilihan konfigurasi optimal bergantung pada kebutuhan spesifik pengguna: sistem yang mengutamakan akurasi prediksi sebaiknya menggunakan $\lambda=0,05$, sedangkan sistem yang mengutamakan keberagaman rekomendasi sebaiknya menggunakan $\lambda=0,50$.

5.2 Saran

Berdasarkan hasil dan keterbatasan penelitian yang telah dilakukan, terdapat beberapa saran untuk pengembangan lebih lanjut.

1. Penelitian ini menggunakan bobot yang ditentukan secara manual melalui eksperimen. Penelitian selanjutnya dapat mengeksplorasi metode pembelajaran otomatis untuk menentukan bobot yang optimal secara adaptif berdasarkan karakteristik pengguna, misalnya menggunakan pendekatan *learning to rank* atau optimasi berbasis *feedback* pengguna.
2. Sistem yang dikembangkan dalam penelitian ini belum mengimplementasikan mekanisme filter konten yang telah dirancang pada subbab 4.9. Penelitian selanjutnya dapat mengembangkan fitur filter konten berbasis *age rating* atau preferensi konten pengguna sebagai lapisan tambahan sebelum proses pemilihan kandidat, sehingga sistem dapat lebih mengakomodasi kebutuhan pengguna yang beragam termasuk pengguna yang ingin membatasi konten berdasarkan nilai tertentu.
3. Dataset yang digunakan dalam penelitian ini adalah MovieLens yang merupakan dataset statis. Penelitian selanjutnya dapat mengeksplorasi

penerapan sistem pada data yang bersifat dinamis dan *real-time*, sehingga preferensi pengguna dapat diperbarui secara berkala seiring bertambahnya riwayat tontonan.

4. Evaluasi dalam penelitian ini dilakukan secara *offline* menggunakan data uji. Penelitian selanjutnya dapat melengkapi evaluasi dengan studi pengguna (*user study*) secara langsung untuk mengukur tingkat kepuasan pengguna terhadap rekomendasi yang dihasilkan, yang merupakan aspek penting yang tidak dapat sepenuhnya ditangkap oleh metrik evaluasi *offline*.

DAFTAR PUSTAKA

- Adomavicius, G., Manouselis, N., & Kwon, Y. (2010). Multi-Criteria Recommender Systems. I In *Recommender systems handbook*. Springer. <https://doi.org/10.1007/978-0-387-85820-3>
- Antoniuk, S. (2025). *Netflix's Algorithm: How Does Netflix Use AI to Personalize Recommendations?*. LITSLINK. Diakses pada 20 November 2025 dari <https://litslink.com/blog/all-about-netflix-artificial-intelligence-the-truth-behind-personalized-content>
- Az Zuhaili, W. (1991). *Tafsir Al Munir Aqidah Syariah Manhaj*. Dar al-Fikr. [https://archive.org/details/tafsir-munir-01_202201/Tafsir Munir 15/page/n425/mode/2up](https://archive.org/details/tafsir-munir-01_202201/Tafsir%20Munir%2015/page/n425/mode/2up)
- Spiegel, Bart. (2025). *Perspectives from the Global Entertainment & Media Outlook 2025–2029*. PwC. Diakses pada 20 November 2025 dari <https://www.pwc.com/gx/en/issues/business-model-reinvention/outlook/insights-and-perspectives.html>
- Benouaret, I., Amer-Yahia, S., & Roy, S. B. (2019). An Efficient Greedy Algorithm for Sequence Recommendation. *Springer-Verlag, 11706 LNCS*, 314–326. https://doi.org/10.1007/978-3-030-27615-7_24
- Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-Based Systems*, 46, 109–132. <https://doi.org/10.1016/j.knosys.2013.03.012>
- Carbonell, J., & Goldstein, J. (1998). The Use of MMR, Diversity-Based Reranking for Reordering Documents and Producing Summaries. *SIGIR 1998 - Proceedings of the 21st Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, 335–336. <https://doi.org/10.1145/290941.291025>
- Chen, L., Zhang, G., & Zhou, H. (2018). Fast greedy map inference for determinantal point process to improve recommendation diversity. *Advances in Neural Information Processing Systems, 2018-Decem*, 5622–5633.
- Cormen, T. H., Leiserson, C. E., Rivest, R. L., & Stein, C. (2009). Introduction to Algorithms 2nd version. In *Massachusetts Institute of Technology*. [https://edutechlearners.com/download/Introduction_to_algorithms-3rd Edition.pdf](https://edutechlearners.com/download/Introduction_to_algorithms-3rd%20Edition.pdf)
- Cremonesi, P., Koren, Y., & Turrin, R. (2010). Performance of Recommender Algorithms on Top-N Recommendation Tasks. *RecSys'10 - Proceedings of the 4th ACM Conference on Recommender Systems*.
- Dergunov, A. (2024). *Maximal Marginal Relevance*. Medium. Diakses pada 20 November 2025 dari <https://medium.com/@adergunov/maximal-marginal-relevance-144c23b42be5>
- Fink, Steve. *Content overload: Streaming audiences plagued by far too many options*. (2024). StudyFinds. Diakses pada 20 November 2025 dari

<https://studyfinds.org/content-overload-streaming/>

- Gupta, S., & Kant, V. (2020). A Review and Classification of Multi-Criteria Recommender Systems. *Proceedings of the International Conference on Intelligent Computing and Control Systems, ICICCS 2020, Iciccs*, 1156–1162. <https://doi.org/10.1109/ICICCS48265.2020.9120983>
- Hamka, H. (1982). *Tafsir Al-Azhar*. Pustaka Panjimas. [https://archive.org/details/tafsiralazhar08_201912/Tafsir Al-Azhar 10/page/n1/mode/2up](https://archive.org/details/tafsiralazhar08_201912/Tafsir%20Al-Azhar%20page/n1/mode/2up)
- Isinkaye, F. O., Folajimi, Y. O., & Ojokoh, B. A. (2015). Recommendation systems: Principles, methods and evaluation. *Egyptian Informatics Journal*, 16(3), 261–273. <https://doi.org/10.1016/j.eij.2015.06.005>
- Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. (2011). An Introduction Recommender Systems. In *Educacao e Sociedade* (Vol. 1, Nomor 1). cambridge university press.
- Jayalakshmi, S., Ganesh, N., Čep, R., & Murugan, J. S. (2022). Movie Recommender Systems: Concepts, Methods, Challenges, and Future Directions. *Sensors*, 22(13). <https://doi.org/10.3390/s22134904>
- Kalmykov, M. (2023). *Navigating Recommendation System Challenges in Video Streaming*. Medium. Diakses pada 20 November 2025 dari <https://maxkalmykov.medium.com/navigating-recommendation-system-challenges-in-video-streaming-03014b92ab61>
- Katsir, I. (1999). Lubaabut Tafsir Min Ibni Katsir. In *Tafsir Ibnu Katsir* (Vol. 5, hal. 614).
- Kemenag. (2022). *Qur'an Kemenag*. <https://quran.kemenag.go.id/quran/per-ayat/surah/96?from=1&to=5>
- Kleinberg, J., & Tardos, E. (1987). Algorithm design. In *Communications of the ACM* (Vol. 30, Nomor 3, hal. 204–212). <https://doi.org/10.1145/214748.214752>
- Kotkov, D., Veijalainen, J., & Wang, S. (2018). How does serendipity affect diversity in recommender systems? A serendipity-oriented greedy algorithm. *Computing*, 102(2), 393–411. <https://doi.org/10.1007/s00607-018-0687-5>
- Levitin, A. (2012). Introduction to The Design and Analysis of Algorithms. In *Pearson Education, Inc., Inc.*, publishing as Addison-Wesley.
- Lopez, H. (2024). *TV's New Big 4: Netflix, YouTube, Amazon and Disney Poised to Dominate*. Variety. Diakses pada 20 November 2025 dari <https://variety.com/2024/tv/news/netflix-youtube-amazon-disney-big-4-streaming-wars-hernan-lopez-1236156334/>
- Manouselis, N., & Costopoulou, C. (2007). Analysis and classification of multi-criteria recommender systems. *World Wide Web*, 10(4), 415–441. <https://doi.org/10.1007/s11280-007-0019-8>

- Naminas, K. (2022). *What Is a Movie Recommendation System in ML? Label Your Data*. Diakses pada 20 November 2025 dari <https://labelyourdata.com/articles/movie-recommendation-with-machine-learning>
- Nassar, N., Jafar, A., & Rahhal, Y. (2020). Multi-criteria collaborative filtering recommender by fusing deep neural network and matrix factorization. *Journal of Big Data*, 7(1). <https://doi.org/10.1186/s40537-020-00309-6>
- Ricci, F., Rokach, L., & Shapira, B. (2015). Recommender System handbook. In *The American Journal of Medicine* (Vol. 32, Nomor 1). Springer Science+Business Media. [https://doi.org/10.1016/0002-9343\(62\)90176-6](https://doi.org/10.1016/0002-9343(62)90176-6)
- Salau, L., Mohamed, H., Abdulsalam, Y. S., & Mohammed, H. (2025). Deep learning-based multi- criteria recommender system for technology-enhanced learning. *Scientific Reports*, 1–17.
- Santos, R. L. T., Peng, J., Macdonald, C., & Ounis, I. (2010). *Explicit Search Result Diversificatio through Sub-queries*. 87–99.
- Shihab, Q. M. (2002). Tafsir Al Mishbah . In *Lentera Hati*. Lentera Hati. <https://archive.org/details/tafsir-al-mishbah-prof-dr.-m.-quraish-shihab-/Tafsir-Al-Mishbah-Jilid-15-Dr.-M.-Quraish-Shihab-pages-deleted/>
- Soham. (2025). *Building a Movie Recommendation System with Machine Learning*. Analytics Vidhya. Diakses pada 20 November 2025 dari <https://www.analyticsvidhya.com/blog/2020/11/create-your-own-movie-movie-recommendation-system/>
- Su, X., & Khoshgoftaar, T. M. (2009). A Survey of Collaborative Filtering Techniques. *Advances in Artificial Intelligence*, 2009(Section 3), 1–19. <https://doi.org/10.1155/2009/421425>
- Vargas, S., & Castells, P. (2011). Rank and relevance in novelty and diversity metrics for recommender systems. *RecSys'11 - Proceedings of the 5th ACM Conference on Recommender Systems*, 109–116. <https://doi.org/10.1145/2043932.2043955>
- Zhao, Y., Wang, Y., Liu, Y., Cheng, X., Aggarwal, C. C., & Derr, T. (2025). Fairness and Diversity in Recommender Systems: A Survey. *ACM Transactions on Intelligent Systems and Technology*, 16(1). <https://doi.org/10.1145/3664928>
- Ziegler, C.-N., Konstan, J. A., & Georg, L. (2009). Improving recommendation lists through neighbor diversification. *Proceedings - 2009 IEEE International Conference on Intelligent Computing and Intelligent Systems, ICIS 2009*, 3, 222–225. <https://doi.org/10.1109/ICICISYS.2009.5358201>

LAMPIRAN

Lampiran 1 Contoh Coding Perencanaan Model

```
import numpy as np
from datetime import datetime

# Load candidate_movies yang sudah memiliki semua kolom normalisasi
candidate_movies = pd.read_csv('candidate_movies_normalized.csv')

# Load genre_score secara terpisah dan gabungkan
genre_score_df = pd.read_csv('candidate_movies_with_genre_score.csv')[['movieId', 'genre_score']]
candidate_movies = candidate_movies.merge(genre_score_df, on='movieId', how='left')

# Pastikan genre_score tidak NaN jika ada film tanpa genre atau masalah lain
candidate_movies['genre_score'] = candidate_movies['genre_score'].fillna(0)

# SEL 4 - hitung final score dengan bobot seimbang
w_genre = 0.25
w_rating = 0.25
w_pop = 0.25
w_year = 0.25

decay_rate = 0.1 # alpha, bisa disesuaikan

# Use the 'year' column for time decay, ensuring it's numeric and handling NaNs
current_year = datetime.now().year
candidate_movies['year'] = candidate_movies['year'].fillna(candidate_movies['year'].median()).astype(int)

# Terapkan time decay ke rating_norm menggunakan tahun rilis film
candidate_movies['rating_decayed'] = candidate_movies.apply(
    lambda row: row['rating_norm'] * np.exp(-decay_rate * (current_year - row['year'])),
    axis=1
)

# Hitung final_score dengan rating yang sudah di-decay
candidate_movies['final_score'] = (
    w_genre * candidate_movies['genre_score'] +
    w_rating * candidate_movies['rating_decayed'] + # <-- pakai rating_decayed
    w_pop * candidate_movies['popularity_norm'] +
    w_year * candidate_movies['year_norm']
)

# Tampilkan candidate_movies dengan final_score yang baru dihitung
print("Candidate Movies dengan Final Score:")
display(candidate_movies[['title', 'final_score', 'genre_score', 'rating_norm', 'popularity_norm', 'year_norm']].head())

# Simpan candidate_movies ke CSV setelah menambahkan final_score
candidate_movies.to_csv('candidate_movies_with_final_score.csv', index=False)
print("✅ File candidate_movies_with_final_score.csv berhasil disimpan!")
```

Dokumentasi implementasi program, hasil pengujian lengkap, serta lampiran pendukung lainnya dapat diakses melalui tautan berikut:

<https://drive.google.com/drive/folders/1q6CVi9ZVTq084kCusbryg1KtlRwi2DtV?usp=sharing>.

RIWAYAT HIDUP



Siti Ma'rifatul Musa'adah, lahir di Lamongan pada tanggal 20 September 2003. Penulis merupakan putri kedua dari pasangan Bapak Muhammad Ishaq dan Ibu Mansurotin. Penulis tumbuh dan menjalani pendidikan di lingkungan yang penuh dukungan serta motivasi untuk terus belajar dan berkembang. Pendidikan formal penulis dimulai dari Taman Kanak-Kanak di TK Muslimat Tarbiyatul Huda dan lulus pada tahun 2010. Selanjutnya penulis menempuh pendidikan di MI Tarbiyatul Huda dan lulus pada tahun 2016, kemudian melanjutkan pendidikan di MTs Tarbiyatut Tholabah dan lulus pada tahun 2019. Setelah itu, penulis melanjutkan pendidikan di MA Tarbiyatut Tholabah dan lulus pada tahun 2022. Pada tahun yang sama, penulis melanjutkan pendidikan ke jenjang perguruan tinggi di Universitas Islam Negeri Maulana Malik Ibrahim Malang, dan memilih program studi Matematika yang ada pada Fakultas Sains dan Teknologi. Selama menjadi mahasiswa, penulis tidak hanya mengikuti kegiatan akademik, tetapi juga aktif dalam berbagai kegiatan organisasi dan pengembangan diri. Berbagai pengalaman selama masa perkuliahan menjadi proses pembelajaran yang berharga bagi penulis, baik dalam hal tanggung jawab, kerja sama, maupun menghadapi berbagai tantangan.



BUKTI KONSULTASI SKRIPSI

Nama : Siti Ma'rifatul Musa'adah
NIM : 220601110028
Fakultas / Jurusan : Sains dan Teknologi / Matematika
Judul Skripsi : Sistem Rekomendasi Film Multi-kriteria Berbasis
Algoritma *Greedy* dengan *Diversity Penalty*
Pembimbing I : Mohammad Nafie Jauhari, M.Si
Pembimbing II : Dr. Mohammad Jamhuri, M.Si

No	Tanggal	Hal	Tanda Tangan
1.	8 September 2025	Konsultasi Bab I, II, dan III	1.
2.	23 Oktober 2025	Konsultasi Bab I, II, dan III	2.
3.	31 Oktober 2025	Konsultasi Kajian Agama Bab I dan II	3.
4.	7 November 2025	ACC Kajian Agama Bab I dan II	4.
5.	10 November 2025	ACC Bab I, II, dan III	5.
6.	10 November 2025	ACC Seminar Proposal	6.
7.	4 Desember 2025	Konsultasi Revisi Seminar Proposal	7.
8.	7 Januari 2026	Konsultasi Bab IV dan V	8.
9.	12 Maret 2026	Konsultasi Bab IV dan V	9.
10.	29 April 2026	Konsultasi Kajian Agama Bab IV	10.
11.	30 April 2026	ACC Kajian Agama Bab IV	11.
12.	30 April 2026	ACC Bab IV dan V	12.
13.	30 April 2026	ACC Seminar Hasil	13.
14.	11 Mei 2026	Konsultasi Revisi Seminar Hasil	14.
15.	13 Mei 2026	Konsultasi Revisi Seminar Hasil Kajian Agama Bab IV	15.



KEMENTERIAN AGAMA RI
UNIVERSITAS ISLAM NEGERI
MAULANA MALIK IBRAHIM MALANG
FAKULTAS SAINS DAN TEKNOLOGI
Jl. Gajayana No.50 Dinoyo Malang Telp. / Fax. (0341)558933

16.	02 Juni 2026	ACC Keseluruhan	16. 6/1
-----	--------------	-----------------	--------------------

Malang, 02 Juni 2026

Mengetahui,

Ketua Program Studi Matematika



Dr. Fachrur Rozi, M.Si.

NIP. 19800527 200801 1 012