

Implementasi HHKBRM Pada Model Rekomendasi Hibrida untuk Perencanaan Kompetensi SDM Rumah Sakit

Fredy Sitinjak^{1*}, Alva Hendi Muhammad², Sri Ngudi Wahyuni³

¹ Ilmu Komputer, S2 PJJ Informatika, Universitas AMIKOM, Yogyakarta, Indonesia

² Ilmu Komputer, S3 Informatika, Universitas AMIKOM, Yogyakarta, Indonesia

³ Ilmu Komputer, S2 Informatika, Universitas AMIKOM, Yogyakarta, Indonesia

Email: ^{1*}fredy@students.amikom.ac.id, ²alva@amikom.ac.id, ³yuni@amikom.ac.id

Email Penulis Korespondensi: fredy@students.amikom.ac.id

Submitted 22-04-2026; Accepted 04-05-2026; Published 30-06-2026

Abstrak

Pengembangan kompetensi sumber daya manusia (SDM) di rumah sakit menjadi semakin penting seiring dengan transformasi digital layanan kesehatan yang menuntut tenaga kesehatan memiliki kemampuan yang adaptif dan berbasis data. Namun, perencanaan kompetensi masih menghadapi sejumlah kendala, seperti keterbatasan data pelatihan (data sparsity), tingginya variasi kebutuhan kompetensi, serta keterbatasan sistem rekomendasi konvensional yang belum mampu menghasilkan rekomendasi yang personal dan kontekstual. Penelitian ini bertujuan untuk mengembangkan model rekomendasi berbasis hibrida, yaitu *Hierarchical Hybrid Knowledge-Based Recommendation Model* (HHKBRM), guna mendukung perencanaan kompetensi SDM rumah sakit secara lebih efektif. Penelitian menggunakan pendekatan kuantitatif eksperimental dengan memanfaatkan data sekunder yang mencakup profil SDM, data pelatihan, riwayat pelatihan, serta data organisasi dan standar kompetensi layanan. Model dikembangkan melalui integrasi pendekatan berbasis pengetahuan, penyaringan berbasis konten, dan penyaringan kolaboratif, serta didukung teknik pengelompokan tingkat kompetensi. Proses analisis meliputi pembersihan data, pemetaan semantik menggunakan metode pembobotan istilah dan pengukuran kemiripan, serta perhitungan skor hibrida untuk menghasilkan rekomendasi pelatihan. Hasil evaluasi menunjukkan bahwa model menghasilkan Precision@10 sebesar 0,030, Recall@10 sebesar 0,303, NDCG@10 sebesar 0,218, Hit Rate@10 sebesar 0,303, dan Diversity@10 sebesar 0,782. Hasil ini menunjukkan bahwa model mampu memberikan rekomendasi yang relevan dengan kualitas peringkat yang baik serta tingkat keberagaman yang tinggi. Secara keseluruhan, model yang diusulkan efektif dalam mendukung perencanaan kompetensi SDM rumah sakit berbasis data dengan menyeimbangkan aspek relevansi dan keberagaman rekomendasi.

Kata Kunci: Analitik SDM; Diversity; Hit Rate; Keberagaman Rekomendasi; Kompetensi SDM; NDCG; Rumah Sakit;

Abstract

The development of human resources (HR) competencies in hospitals has become increasingly important in the era of digital healthcare transformation, which requires healthcare professionals to possess adaptive and data-driven capabilities. However, competency planning still faces several challenges, including limited training data (data sparsity), high variability in competency needs, and the limitations of conventional recommendation systems that are not yet capable of providing personalized and contextual recommendations. This study aims to develop a hybrid recommendation model, namely the Hierarchical Hybrid Knowledge-Based Recommendation Model (HHKBRM), to support more effective competency planning for hospital HR. This research adopts a quantitative experimental approach using secondary data, including HR profiles, training data, training histories, organizational data, and competency standards. The proposed model integrates knowledge-based, content-based filtering, and collaborative filtering approaches, supported by a competency level categorization technique. The analytical process includes data preprocessing, semantic mapping using term weighting and similarity measurement, and hybrid score computation to generate relevant training recommendations. The evaluation results indicate that the model achieves a Precision@10 of 0,054, Recall@10 of 0,300, NDCG@10 of 0,299, Hit Rate@10 of 0,300, and Diversity@10 of 0,849. These results demonstrate that the model is capable of providing relevant recommendations with good ranking quality and high diversity. Overall, the proposed model is effective in supporting data-driven competency planning for hospital human resources by balancing recommendation relevance and diversity.

Keywords: HR Analytics; Diversity; Hit Rate; Recommendation Diversity; Human Resource Competency; NDCG; Hospital;

1. PENDAHULUAN

Transformasi digital di sektor kesehatan telah membawa perubahan yang signifikan dalam pengelolaan sumber daya manusia (SDM), terutama pada rumah sakit yang memiliki kompleksitas tinggi baik dari sisi pelayanan maupun operasional. Pemanfaatan teknologi seperti big data, artificial intelligence (AI), dan human resource analytics (HR analytics) semakin banyak digunakan untuk meningkatkan kualitas pengambilan keputusan terkait tenaga kesehatan. Studi menunjukkan bahwa organisasi yang mengimplementasikan HR analytics mampu meningkatkan efisiensi dalam pengelolaan kompetensi hingga lebih dari 50% melalui pendekatan berbasis data dalam identifikasi kebutuhan pelatihan dan pengembangan [1]. Selain itu, integrasi sistem digital seperti Human Resource Information System (HRIS) dengan predictive analytics memungkinkan proses pengelolaan kompetensi yang lebih dinamis, adaptif, dan sesuai dengan kebutuhan aktual organisasi [2].

Dalam konteks rumah sakit, kebutuhan akan tenaga kesehatan yang memiliki kompetensi sesuai dengan tuntutan layanan semakin meningkat, seiring dengan berkembangnya kompleksitas penyakit, kemajuan teknologi medis, serta peningkatan standar kualitas layanan. Penelitian terbaru juga menunjukkan adanya peningkatan kebutuhan terhadap kompetensi berbasis digital dan AI di sektor kesehatan, sehingga diperlukan pendekatan baru dalam perencanaan SDM yang lebih responsif dan berbasis data [3]. Oleh karena itu, penggunaan sistem rekomendasi (*recommender system*) mulai

diadopsi sebagai salah satu solusi untuk mendukung pengambilan keputusan terkait pelatihan, pengembangan, dan penempatan tenaga kerja secara lebih personal, akurat, dan kontekstual [4].

Namun demikian, pendekatan konvensional dalam perencanaan kompetensi SDM rumah sakit masih menghadapi berbagai keterbatasan. Sistem yang ada umumnya belum mampu menghasilkan rekomendasi yang bersifat personal dan adaptif, terutama akibat keterbatasan data serta metode analitik yang digunakan. Salah satu tantangan utama adalah data sparsity, yaitu minimnya data interaksi antara individu dan program pelatihan, yang berdampak pada rendahnya kualitas rekomendasi [5]. Selain itu, banyak sistem yang belum mengakomodasi analisis kesenjangan kompetensi (*competency gap*) secara komprehensif, sehingga rekomendasi yang dihasilkan belum sepenuhnya relevan dengan kebutuhan individu maupun organisasi [6].

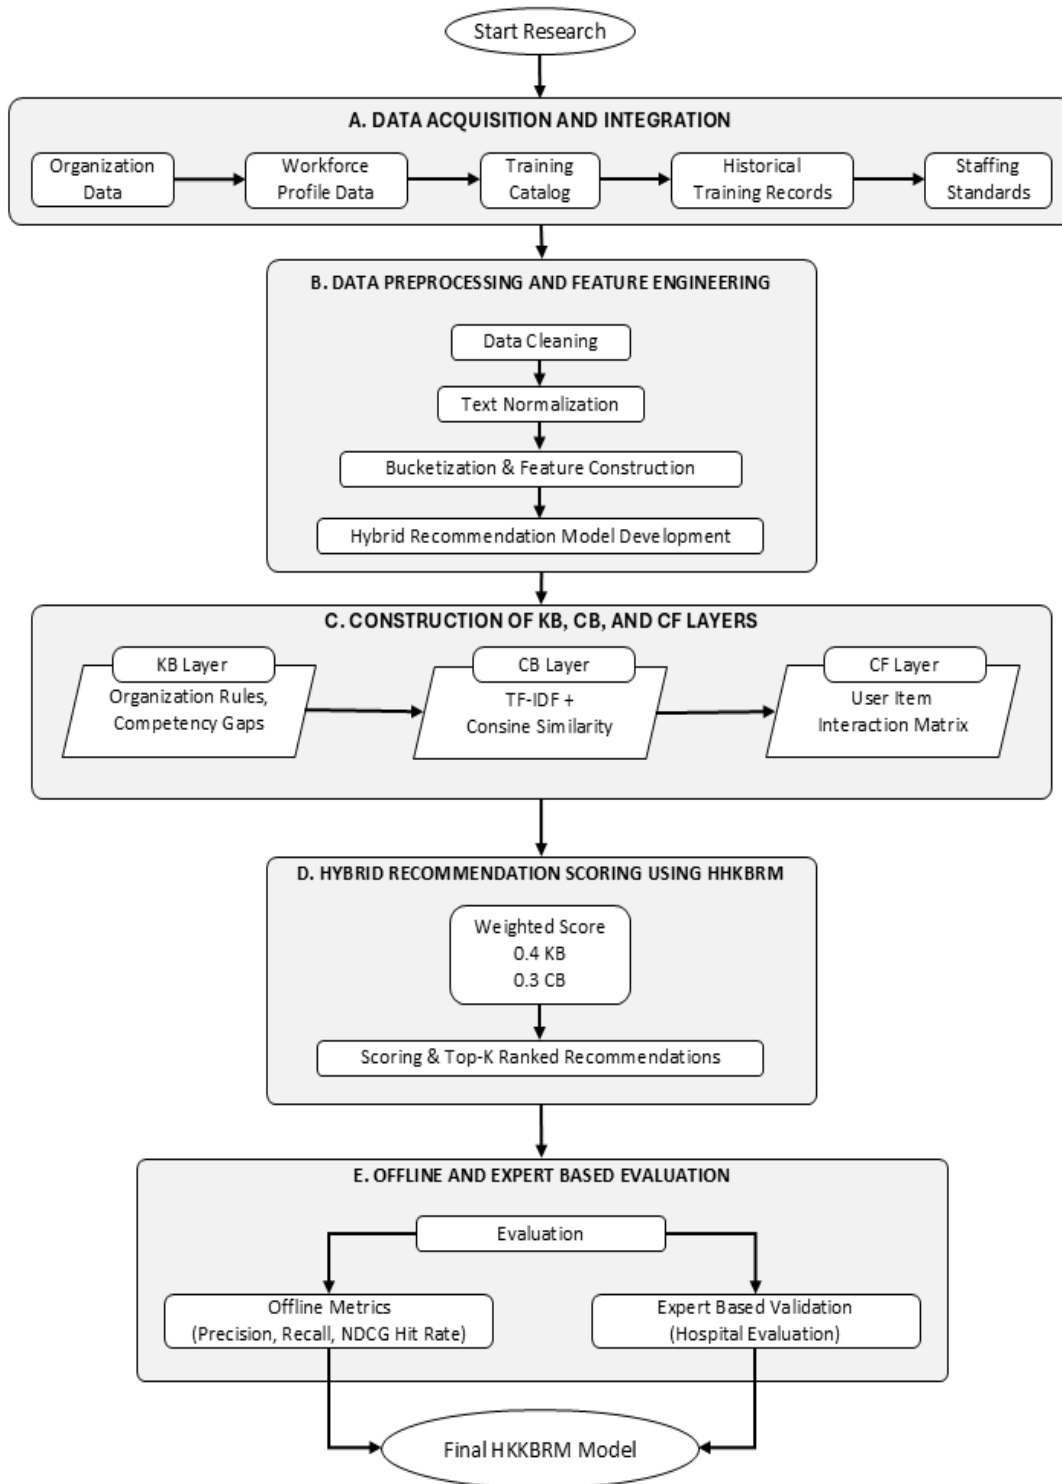
Lebih lanjut, sebagian besar penelitian sebelumnya masih mengandalkan pendekatan tunggal, seperti collaborative filtering atau content-based filtering, yang masing-masing memiliki keterbatasan dalam menangkap kompleksitas hubungan antara profil individu, kebutuhan organisasi, dan dinamika kompetensi. Oleh karena itu, diperlukan pendekatan hybrid recommendation system yang mampu mengintegrasikan berbagai metode untuk menghasilkan rekomendasi yang lebih akurat dan relevan. Beberapa penelitian menunjukkan bahwa model hybrid yang menggabungkan teknik machine learning, analitik data, dan informasi kompetensi dapat menghasilkan sistem rekomendasi yang lebih robust dan kontekstual dalam pengembangan SDM [7][8].

Penelitian ini menawarkan solusi melalui pengembangan *Hybrid Healthcare Knowledge-Based Recommendation Model* (HHKBRM) yang mengintegrasikan pendekatan *knowledge-based*, *content-based filtering*, dan *collaborative filtering* dalam kerangka multi-layer. Model ini dirancang untuk mengatasi keterbatasan sistem rekomendasi konvensional, khususnya dalam kondisi data sparsity dan kebutuhan kompetensi yang dinamis, dengan menggabungkan informasi profil individu, kebutuhan organisasi, serta analisis kesenjangan kompetensi secara simultan. Pendekatan ini diharapkan mampu menghasilkan rekomendasi yang lebih adaptif, kontekstual, dan relevan dibandingkan metode tunggal yang digunakan pada penelitian sebelumnya.

2. METODOLOGI PENELITIAN

2.1 Desain Penelitian

Penelitian ini mengadopsi pendekatan kuantitatif dengan desain eksperimen (experimental research) yang bertujuan untuk mengembangkan sekaligus mengevaluasi model *Hybrid Healthcare Knowledge-Based Recommendation Model* (HHKBRM) dalam konteks perencanaan kompetensi SDM rumah sakit. Data yang digunakan merupakan data sekunder yang bersumber dari sistem informasi rumah sakit, yang mencakup: (1) data profil SDM seperti jabatan, unit kerja, dan kompetensi, (2) data program pelatihan, (3) riwayat pelatihan individu, (4) data organisasi yang meliputi kebutuhan unit dan prioritas layanan, serta (5) standar kompetensi layanan kesehatan. Pengumpulan data dilakukan melalui metode dokumentasi dan integrasi basis data HRIS, yang merupakan pendekatan umum dalam studi HR analytics berbasis data besar [1][2]. Untuk memberikan gambaran Alur kerja penelitian dan proses pengembangan model yang diusulkan, Gambar 1 menyajikan kerangka HHKBRM dengan disusun dalam lima tahapan utama yang meliputi Akuisisi data dan integrasi, preprocessing dan fitur pendukung, pembentukan layer KB,CC dan CF, dan tahapan evaluasi offline dan evaluasi elevator.



Gambar 1. Diagram Alur Penelitian

Berdasarkan Gambar 1, alur penelitian dimulai dari tahap data acquisition and integration yang mencakup pengumpulan data organisasi, profil tenaga kerja, katalog pelatihan, riwayat pelatihan, serta standar kebutuhan tenaga kerja. Selanjutnya, pada tahap data preprocessing and feature engineering, dilakukan proses pembersihan data, normalisasi teks, serta pembentukan fitur untuk menghasilkan representasi data yang siap digunakan dalam model. Pada tahap berikutnya, yaitu construction of KB, CB, and CF layers, sistem membangun tiga komponen utama, yaitu knowledge-based layer yang memanfaatkan aturan organisasi dan analisis kesenjangan kompetensi, content-based filtering yang menggunakan pendekatan TF-IDF dan cosine similarity, serta collaborative filtering yang memanfaatkan matriks interaksi pengguna. Ketiga pendekatan ini kemudian diintegrasikan pada tahap hybrid recommendation scoring menggunakan pembobotan tertentu untuk menghasilkan skor rekomendasi dan menentukan peringkat Top-K. Tahap akhir adalah evaluation, yang dilakukan melalui dua pendekatan, yaitu evaluasi offline menggunakan metrik seperti precision, recall, NDCG, dan hit rate, serta validasi berbasis ahli (expert-based validation). Hasil dari keseluruhan proses

ini menghasilkan model akhir HHKBRM yang siap digunakan dalam mendukung perencanaan kompetensi SDM rumah sakit.

2.2 Materials Dataset

Subjek penelitian terdiri dari tenaga kesehatan aktif di rumah sakit yang memenuhi kriteria tertentu, yaitu memiliki riwayat pelatihan, tercatat dalam sistem SDM, serta berkontribusi pada layanan prioritas. Teknik pengambilan sampel menggunakan purposive sampling, dengan mempertimbangkan kelengkapan data sebagai syarat utama dalam proses pengembangan model rekomendasi [6].

2.2.1 Data Organisasi

Dataset organisasi berisi informasi tingkat unit kerja yang digunakan untuk merepresentasikan prioritas kompetensi institusional. Atribut yang digunakan meliputi: kode unit, nama unit, layanan kesehatan prioritas, tingkat risiko, rasio kebutuhan kompetensi, dan direktorat.

2.2.2 Data Profil Pegawai

Dataset ini memuat atribut tingkat karyawan untuk mendukung profil kompetensi individual. Data yang diambil meliputi: Nomor Induk Karyawan (NIK/NIP), unit kerja, direktorat, jenis profesi, kepakaran, jabatan, serta pangkat dan status kepegawaian.

2.2.3 Data Katalog Program Pelatihan

Dataset ini berfungsi sebagai repositori item dalam proses rekomendasi. Atributnya meliputi: ID pelatihan, judul pelatihan, deskripsi topik semantik, target kompetensi, kriteria peserta, kriteria profesi, kategori dan jenis pelatihan, Jam Pelajaran (JPL), serta bobot Satuan Kredit Profesi (SKP).

2.2.4 Standar Personel Layanan Prioritas

Dataset standar kompetensi ini mencakup standar kebutuhan tenaga untuk layanan strategis rumah sakit, antara lain: kardiovaskular, kanker, stroke, kesehatan ibu dan anak (KIA), serta uronefrologi. Dataset ini mendefinisikan kebutuhan kompetensi ideal yang menjadi acuan dalam identifikasi gap kompetensi.

2.2.5 Riwayat Pelatihan Pegawai

Data partisipasi pelatihan historis dalam rentang tahun 2022–2025 mencakup: identitas karyawan, nama peserta, judul pelatihan yang pernah diikuti, tanggal pelaksanaan, lokasi, durasi jam pelatihan, dan penyelenggara. Data ini krusial untuk mekanisme *Collaborative Filtering* guna melihat pola pengembangan kompetensi sebelumnya. Data ini dimanfaatkan untuk membangun pola-pola kolaboratif serta kesamaan perilaku pegawai. Untuk memberikan gambaran komprehensif mengenai karakteristik dataset yang digunakan dalam penelitian ini, Tabel 1 menyajikan deskripsi statistik dari setiap sumber data, termasuk jumlah data, jumlah fitur, serta atribut yang digunakan dalam proses pengembangan model.

Tabel 1. Deskripsi Statistik Dataset

Nama Dataset	Jumlah Data	Jumlah Fitur	Nama Fitur
history_pelatihan	608	9	nik, nickname, nama_peserta, nama_kegiatan, tgl_pelaksanaan, tempat, jumlah_jp, penyelenggara, tahun
organisasi	56	6	unit_kode, nama_unit, layanan_prioritas_list, tingkat_risiko, rasio_kebutuhan_kompetensi, direktorat
pelatihan	680	20	pelatihan_id, nama, topik_semantik, kompetensi_target_codes, kriteria_peserta, instansi_pengusul_penyelenggara, metode_pelatihan, organisasi_profesi, kriteria_peserta_tenaga_kesehatan, kategori_pelatihan, jenis_pelatihan, jpl, angka_kredit, skp, max_per_kelas, status_aktif, status_publish, tgl_perubahan, catatan, tahun
sdm	2188	17	nickname, nama, nik, unit_kerja, unit_kerja2, direktorat, jenis_tenaga, count, jk, gol, tmt_gol, tenaga, keahlian, nama_jabatan, tmt_job, jabatan_simka, status
standar_sdm_jantung	26	3	no, sdm_dibutuhkan, pelayanan_pengampuan
standar_sdm_kanker	78	3	no, sdm_dibutuhkan, pelayanan_pengampuan
standar_sdm_stroke	4	3	no, sdm_dibutuhkan, pelayanan_pengampuan
standar_sdm_kia	32	3	no, sdm_dibutuhkan, pelayanan_pengampuan
standar_sdm_uronefrologi	31	3	no, sdm_dibutuhkan, pelayanan_pengampuan

Berdasarkan Tabel 1, dataset yang digunakan dalam penelitian ini terdiri dari beberapa sumber utama yang saling melengkapi. Dataset history_pelatihan berperan penting dalam mendukung pendekatan collaborative filtering dengan menyediakan informasi riwayat pelatihan pegawai. Dataset sdm memiliki jumlah data terbesar, yaitu 2188 entri, yang

mencerminkan keragaman profil tenaga kerja dan menjadi dasar dalam analisis karakteristik individu. Sementara itu, dataset pelatihan memiliki jumlah fitur paling banyak, yang menunjukkan kompleksitas atribut pelatihan yang digunakan dalam proses pemodelan berbasis konten.

Selain itu, dataset standar kompetensi seperti standar_sdm_jantung, standar_sdm_kanker, standar_sdm_stroke, standar_sdm_kia, dan standar_sdm_uronefrologi digunakan dalam pendekatan *knowledge-based* untuk mengidentifikasi kesenjangan kompetensi berdasarkan kebutuhan layanan prioritas. Integrasi berbagai dataset ini memungkinkan model HHKBRM untuk menggabungkan informasi historis, karakteristik individu, serta kebutuhan organisasi secara komprehensif dalam menghasilkan rekomendasi pelatihan yang lebih relevan dan kontekstual.

2.3 Tahapan Analisis

Tahapan analisis data diawali dengan proses preprocessing, yang meliputi text cleaning, normalisasi data, serta ekstraksi fitur menggunakan metode TF-IDF (Term Frequency–Inverse Document Frequency) untuk mengubah informasi kompetensi dan deskripsi pelatihan ke dalam bentuk representasi numerik. Selanjutnya, dilakukan proses semantic matching dengan memanfaatkan cosine similarity guna mengukur tingkat kemiripan antara profil kompetensi SDM dan konten pelatihan. Pendekatan ini merupakan metode yang umum digunakan dalam sistem rekomendasi berbasis konten [9][10].

2.4 Metode HHKBRM yang Diusulkan

Model HHKBRM dikembangkan melalui empat lapisan utama, yaitu: (1) Knowledge-Based layer, yang berfungsi mengidentifikasi kesenjangan kompetensi melalui teknik bucketization dengan kategori rendah (0,4), sedang (0,7), dan tinggi (1,0); (2) Content-Based Filtering, yang melakukan pencocokan antara profil individu dan atribut pelatihan; (3) Collaborative Filtering, yang memanfaatkan user-item matrix serta *cosine similarity* untuk mengidentifikasi pola preferensi antar pengguna; dan (4) Hybrid Scoring, yang mengintegrasikan ketiga pendekatan tersebut melalui persamaan:

$$Score_{(u,i)} = CB_{(u,i)} + \alpha.KB_{(u,i)} + \beta.CF_{(u,i)} \quad (1)$$

Pendekatan hybrid ini dipilih karena terbukti mampu meningkatkan tingkat akurasi serta relevansi rekomendasi dibandingkan dengan penggunaan metode tunggal [11][12].

2.5 Evaluasi Model

Evaluasi performa model dilakukan menggunakan beberapa metrik yang umum digunakan dalam sistem rekomendasi, yaitu Precision@K, Recall@K, NDCG@K, Hit Rate@K, dan Diversity@K. Precision dan Recall digunakan untuk menilai tingkat akurasi serta cakupan rekomendasi, sedangkan NDCG (*Normalized Discounted Cumulative Gain*) digunakan untuk mengukur kualitas pemeringkatan dengan mempertimbangkan posisi item yang relevan [13]. Hit Rate digunakan untuk mengevaluasi keberhasilan sistem dalam memberikan setidaknya satu rekomendasi yang relevan kepada pengguna, yang sangat penting dalam konteks pelatihan SDM rumah sakit. Sementara itu, Diversity digunakan untuk memastikan bahwa rekomendasi yang dihasilkan memiliki variasi yang memadai, sehingga dapat mendukung pengembangan kompetensi lintas bidang. Kombinasi metrik evaluasi tersebut memberikan gambaran yang komprehensif terhadap kinerja model, sehingga hasil penelitian dapat dinilai valid, reliabel, serta memiliki relevansi praktis dalam pengambilan keputusan berbasis data [14].

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil evaluasi model yang diusulkan beserta analisis performanya berdasarkan berbagai metrik standar, yaitu Precision, Recall, NDCG, Hit Rate, dan Diversity. Evaluasi dilakukan untuk memberikan gambaran menyeluruh terkait akurasi, cakupan, kualitas pemeringkatan, serta keberagaman rekomendasi. Selain penyajian kuantitatif, hasil juga dianalisis untuk mengidentifikasi pola dan trade-off kinerja model dalam konteks perencanaan kompetensi SDM rumah sakit.

3.1 Hasil Evaluasi Model

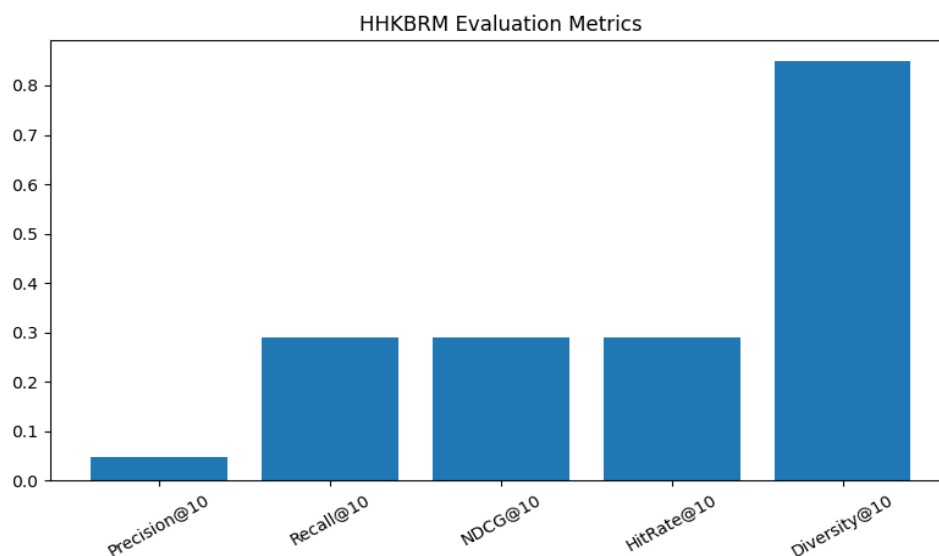
Pada tahap implementasi, model HHKBRM diterapkan melalui serangkaian proses yang terintegrasi mulai dari pengolahan data hingga menghasilkan rekomendasi akhir. Proses diawali dengan preprocessing data dan ekstraksi fitur untuk membentuk representasi numerik dari data kompetensi, profil pegawai, dan pelatihan. Selanjutnya, pendekatan content-based filtering digunakan untuk menghitung tingkat kesamaan antar item menggunakan metode TF-IDF dan cosine similarity. Pada tahap berikutnya, collaborative filtering memanfaatkan riwayat pelatihan untuk mengidentifikasi pola preferensi pengguna. Sementara itu, knowledge-based layer digunakan untuk menghitung kesenjangan kompetensi berdasarkan kebutuhan organisasi. Hasil dari ketiga pendekatan tersebut kemudian diintegrasikan melalui mekanisme hybrid scoring dan dilanjutkan dengan proses re-ranking untuk menghasilkan daftar rekomendasi akhir.

Untuk mengukur kinerja model yang dihasilkan, dilakukan evaluasi menggunakan beberapa metrik standar pada sistem rekomendasi, yaitu Precision, Recall, NDCG, Hit Rate, dan Diversity. Hasil evaluasi performa model HHKBRM disajikan pada Tabel 2.

Tabel 2. Performa Evaluasi Model HHKBRM

Matrik	Score
Precision@10	0,0303
Recall@10	0,3030
NDCG@10	0,2182
HitRate@10	0,3030
Diversity@10	0,7824

Berdasarkan Tabel 2, model HHKBRM menunjukkan nilai *Recall* dan *Hit Rate* yang relatif lebih tinggi dibandingkan *Precision*, yang mengindikasikan bahwa model memiliki kemampuan yang baik dalam menjangkau item yang relevan bagi pengguna. Selain itu, nilai *Diversity* yang tinggi menunjukkan bahwa sistem mampu menghasilkan rekomendasi yang beragam, sehingga mendukung eksplorasi kompetensi lintas bidang. Namun demikian, nilai *Precision* yang relatif rendah menunjukkan bahwa tingkat ketepatan rekomendasi masih perlu ditingkatkan. Untuk memberikan gambaran yang lebih intuitif mengenai distribusi performa model, hasil evaluasi divisualisasikan dalam bentuk grafik seperti yang ditunjukkan pada Gambar 2. Evaluasi dilakukan menggunakan dataset yang terdiri dari 2188 data SDM, 680 data pelatihan, dan 608 riwayat pelatihan. Visualisasi ini bertujuan untuk memperlihatkan perbandingan antar metrik evaluasi secara lebih jelas.



Gambar 2. Grafik Evaluasi Performa Model HHKBRM

Berdasarkan Gambar 2, terlihat bahwa nilai *Diversity* merupakan yang paling tinggi dibandingkan metrik lainnya, yang mengindikasikan bahwa sistem mampu menghasilkan rekomendasi pelatihan yang beragam dan tidak terfokus pada satu jenis kompetensi. Sebaliknya, nilai *Precision* yang relatif rendah menunjukkan bahwa tingkat kecocokan antara rekomendasi dengan preferensi historis pengguna masih terbatas, yang merupakan karakteristik umum pada dataset dengan tingkat sparsity yang tinggi. Temuan ini mengindikasikan bahwa model HHKBRM tidak hanya berfokus pada akurasi, tetapi juga menekankan pada aspek eksplorasi dalam rekomendasi. Dengan demikian, sistem dirancang untuk memperluas peluang pengembangan kompetensi pengguna, bukan sekadar mereplikasi pola pelatihan sebelumnya, sehingga mendukung identifikasi kebutuhan kompetensi baru yang belum tercermin dalam data historis.

3.2 Analisis Hasil Evaluasi

Pada tahap awal, model *hybrid* dirancang menggunakan pendekatan *weighted linear combination* pada persamaan (2) yang menggabungkan komponen *knowledge-based*, *content-based*, dan *collaborative filtering* secara langsung. Pendekatan ini merupakan salah satu strategi umum dalam sistem rekomendasi *hybrid*, di mana skor dari beberapa metode digabungkan secara linear untuk menghasilkan rekomendasi akhir [15] [16]. Namun, pendekatan ini memiliki keterbatasan karena setiap komponen berkontribusi secara simultan terhadap skor akhir, sehingga berpotensi mengganggu struktur peringkat utama, terutama ketika salah satu komponen memiliki tingkat akurasi yang lebih rendah atau ketika data bersifat sparse [17].

$$Score = 0,5 (KB) + 0,3 (CB) + 0,2 (CF) \quad (2)$$

Untuk mengatasi keterbatasan tersebut, penelitian ini mengadopsi pendekatan additive hybrid atau re-ranking strategy, di mana *Content-Based Filtering* digunakan sebagai basis utama dalam pembentukan ranking awal, sementara *Knowledge-Based* dan *Collaborative Filtering* berperan sebagai faktor penyesuaian (boosting) dengan implementasi

persamaan (1). Pendekatan ini sejalan dengan konsep post-processing atau re-ranking dalam sistem rekomendasi, yang bertujuan untuk meningkatkan kualitas hasil tanpa merusak struktur peringkat awal [18][16]. Hasil pada Tabel 3 menunjukkan bahwa integrasi informasi tambahan melalui pendekatan re-ranking mampu mempertahankan stabilitas peringkat utama sekaligus meningkatkan relevansi sistem, di mana efektivitas pendekatan diuji melalui perbandingan metode *weighted linear* dan *additive re-ranking* pada berbagai model rekomendasi. Analisis yang disajikan menunjukkan bahwa hasil kinerja dari teknik-teknik tersebut didokumentasikan dalam Tabel 3

Tabel 3. Perbandingan Kinerja Metode Re-ranking vs Weighted Linear

Model	Pendekatan	Precision	Recall	NDCG	HitRate	Diversity
CF	<i>Weighted Linear & Additive Re-ranking</i>	0,0083	0,0827	0,0564	0,0827	0,8721
CB	<i>Weighted Linear & Additive Re-ranking</i>	0,0288	0,2879	0,2142	0,2879	0,7823
HHKBRM	<i>Weighted Linear</i>	0,0288	0,288	0,2041	0,2879	0,7857
HHKBRM	<i>Additive Re-ranking</i>	0,0303	0,3030	0,2182	0,3030	0,7824

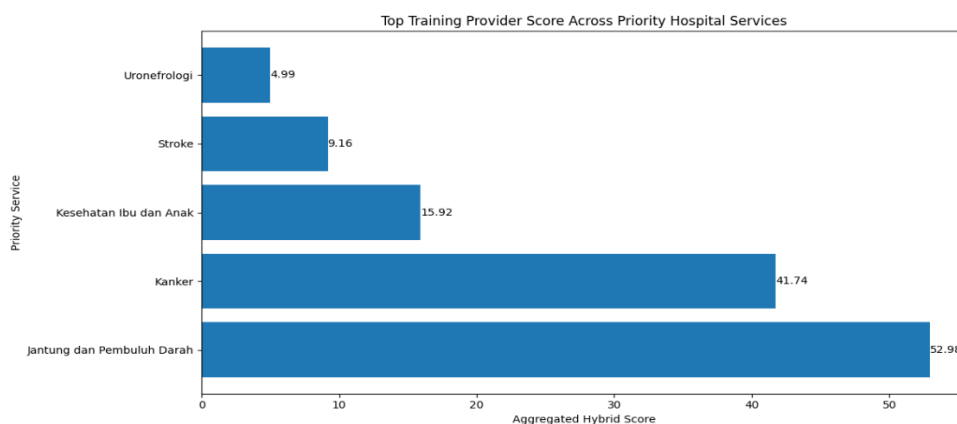
Berdasarkan Tabel 3, model HHKBRM dengan pendekatan *additive re-ranking* menunjukkan peningkatan kinerja dibandingkan metode *weighted linear* pada hampir seluruh metrik evaluasi. Model ini mencapai nilai Precision@10 sebesar 0,0303, Recall@10 sebesar 0,3030, NDCG@10 sebesar 0,2182, serta HitRate@10 sebesar 0,3030, yang lebih tinggi dibandingkan pendekatan *weighted linear*. Meskipun nilai Diversity@10 sedikit menurun menjadi 0,7824, nilai tersebut tetap menunjukkan tingkat keberagaman rekomendasi yang tinggi, namun dengan tingkat presisi yang relatif rendah. Dalam literatur sistem rekomendasi, metrik *precision*, *recall*, dan NDCG merupakan metrik standar untuk mengukur akurasi dan kualitas pemeringkatan, sementara diversity digunakan untuk menilai variasi rekomendasi agar tidak terjadi *over-specialization* [4][19][20]. Kombinasi metrik ini penting karena evaluasi modern tidak hanya berfokus pada akurasi, tetapi juga pada kualitas pengalaman pengguna secara menyeluruh, termasuk eksplorasi dan keberagaman [21][22].

Dari perspektif *trade-off* antara *precision* dan *recall*, HHKBRM cenderung berorientasi pada *recall*, yang terlihat dari rendahnya *precision* namun relatif tingginya *recall*. Hal ini menunjukkan bahwa model mampu menjangkau sebagian besar item relevan, meskipun tidak semua rekomendasi yang diberikan memiliki tingkat relevansi tinggi. Fenomena ini sejalan dengan temuan penelitian bahwa peningkatan recall sering kali mengorbankan *precision* dalam sistem rekomendasi, terutama ketika model dirancang untuk memperluas cakupan dan eksplorasi pengguna [23][24]. Dalam konteks pengembangan kompetensi, pendekatan berbasis *recall* ini dinilai relevan karena memungkinkan pengguna mengeksplorasi lebih banyak alternatif pelatihan, yang dalam praktiknya seringkali lebih bernilai dibandingkan rekomendasi yang sangat sempit namun presisi tinggi [4] [25].

Selanjutnya, nilai NDCG@10 sebesar 0,2182 menunjukkan kualitas pemeringkatan yang moderat, di mana item relevan telah ditempatkan relatif lebih tinggi, meskipun belum optimal. Sementara itu, HitRate@10 sebesar 0,3030 mengindikasikan bahwa sekitar 30% pengguna menerima setidaknya satu rekomendasi relevan, yang secara praktis sudah memberikan dampak signifikan dalam sistem rekomendasi pelatihan. Di sisi lain, nilai Diversity@10 yang tinggi (0,7824) menjadi keunggulan utama karena menunjukkan kemampuan model dalam menghasilkan rekomendasi yang variatif dan mendorong eksplorasi lintas kompetensi. Literatur terkini menegaskan bahwa peningkatan *diversity* sering kali berhubungan dengan penurunan akurasi, namun tetap penting untuk menghindari bias popularitas dan meningkatkan kepuasan jangka panjang pengguna [4] [26] [27]. Dengan demikian, HHKBRM dapat dikategorikan sebagai model yang efektif dalam menyeimbangkan eksplorasi dan cakupan, meskipun masih memerlukan optimasi pada aspek presisi dan pemeringkatan.

3.3 Analisis Berdasarkan Layanan Prioritas

Selain evaluasi berbasis metrik, analisis juga dilakukan untuk melihat bagaimana model merepresentasikan kebutuhan kompetensi pada layanan prioritas rumah sakit. Hasil analisis ini divisualisasikan pada Gambar 3.



Gambar 3. Distribusi Skor Pelatihan Pada Layanan Prioritas Rumah Sakit

Berdasarkan Gambar 3, terlihat bahwa layanan Jantung dan Pembuluh Darah memiliki skor agregat tertinggi, diikuti oleh layanan Kanker, sementara layanan lainnya seperti Kesehatan Ibu dan Anak, Stroke, dan Uronefroplogi memiliki skor yang relatif lebih rendah. Pola ini menunjukkan bahwa model secara konsisten memprioritaskan rekomendasi pada layanan dengan kebutuhan kompetensi yang lebih tinggi.

Fenomena ini tidak terlepas dari peran *knowledge-based* layer dalam model, yang memanfaatkan informasi terkait unit kerja dan rasio kebutuhan kompetensi sebagai dasar dalam proses rekomendasi. Dengan demikian, sistem tidak hanya mempertimbangkan preferensi historis pengguna, tetapi juga mengakomodasi kebutuhan strategis organisasi. Secara keseluruhan, hasil ini menunjukkan bahwa model HHKBRM mampu mengintegrasikan berbagai sumber informasi untuk menghasilkan rekomendasi yang tidak hanya relevan secara individual, tetapi juga selaras dengan prioritas layanan rumah sakit. Hal ini memperkuat posisi model sebagai pendekatan yang tidak hanya bersifat teknis, tetapi juga kontekstual dan aplikatif dalam perencanaan SDM kesehatan.

3.4 Pembahasan

Hasil penelitian ini menunjukkan bahwa pendekatan hybrid recommendation system yang menggabungkan *knowledge-based*, *content-based filtering*, dan *collaborative filtering* mampu menghasilkan performa yang lebih seimbang dibandingkan pendekatan tunggal. Dalam implementasi ini, setiap komponen memiliki peran yang saling melengkapi, di mana *knowledge-based* layer meningkatkan relevansi berdasarkan kebutuhan organisasi, *content-based filtering* memastikan kesesuaian profil individu dengan pelatihan, dan *collaborative filtering* menangkap pola preferensi kolektif pengguna.

Kombinasi ketiga pendekatan tersebut menghasilkan keseimbangan antara eksploitasi (akurasi rekomendasi) dan eksplorasi (keberagaman rekomendasi), yang merupakan tantangan utama dalam pengembangan sistem rekomendasi modern [25]. Dibandingkan dengan penelitian sebelumnya, model ini memiliki keunggulan pada integrasi pendekatan *knowledge-based* dalam domain HR, penekanan pada aspek diversity sebagai indikator utama, serta penggunaan Hit Rate sebagai metrik evaluasi berbasis kebutuhan praktis. Sebagian besar penelitian sebelumnya cenderung hanya berfokus pada metrik akurasi seperti precision dan recall, tanpa mempertimbangkan aspek keberagaman rekomendasi [21].

Untuk mengevaluasi efektivitas model yang diusulkan, dilakukan perbandingan dengan dua baseline utama seperti yang ditunjukkan pada Tabel 4 perbandingan performa model, yaitu *Collaborative Filtering* (CF) dan *Content-Based Filtering* (CB). Hasil eksperimen menunjukkan bahwa model *Hybrid* (HHKBRM) memberikan performa terbaik dibandingkan kedua baseline tersebut. Dibandingkan dengan CF, model *hybrid* mampu meningkatkan *Precision* dari 0,0083 menjadi 0,0303 serta *Recall* dari 0,0827 menjadi 0,3030. Sementara itu, dibandingkan dengan CB, model *hybrid* juga menunjukkan peningkatan meskipun relatif kecil, yang mengindikasikan bahwa integrasi *knowledge-based* dan *collaborative filtering* mampu memberikan kontribusi tambahan terhadap kualitas rekomendasi.

Tabel 4. Perbandingan Performa Model

Model	Precision	Recall	NDCG	HitRate	Diversity
CF	0,0083	0,0827	0,0564	0,0827	0,8721
CB	0,0288	0,2879	0,2142	0,2879	0,7823
HHKBRM	0,0303	0,3030	0,2182	0,3030	0,7824

Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan. Tingginya data sparsity menjadi faktor utama yang memengaruhi rendahnya nilai precision. Selain itu, penggunaan bobot hybrid yang bersifat statis (0,5; 0,3; 0,2) belum dioptimalkan secara adaptif. Keterbatasan lain terletak pada penggunaan dataset yang hanya berasal dari satu institusi, sehingga kemampuan generalisasi model masih perlu diuji lebih lanjut. Selain itu, model belum mengakomodasi pendekatan berbasis *deep learning* maupun fitur kontekstual yang lebih kompleks.

Di sisi lain, beberapa faktor yang mendukung kinerja model antara lain integrasi multi-layer (KB, CB, dan CF), penggunaan representasi teks berbasis TF-IDF, serta adanya proses pemetaan semantik antar pelatihan. Namun, performa model masih dapat ditingkatkan dengan mengatasi ketidakseimbangan data serta menambahkan implicit feedback seperti interaksi pengguna atau preferensi personal.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa model Hybrid Healthcare Knowledge-Based Recommendation Model (HHKBRM) mampu memberikan pendekatan yang lebih komprehensif dalam memahami dan mendukung perencanaan kompetensi SDM rumah sakit berbasis data. Dengan mengintegrasikan kebutuhan organisasi, profil individu, serta riwayat pelatihan, model ini mampu menghasilkan sistem rekomendasi yang lebih adaptif dan kontekstual. Dari hasil evaluasi, terlihat bahwa model memiliki performa yang cukup baik, terutama pada aspek cakupan rekomendasi (recall) dan keberagaman (diversity). Hal ini menunjukkan bahwa sistem tidak hanya mampu menangkap kebutuhan kompetensi pengguna, tetapi juga memberikan alternatif pelatihan yang beragam untuk mendukung pengembangan multi-skill tenaga kesehatan. Meskipun demikian, nilai precision yang relatif rendah masih menjadi konsekuensi dari karakteristik data yang cenderung sparse, yang umum terjadi pada domain SDM dan pelatihan. Selain itu, penggunaan metrik Hit Rate memperlihatkan bahwa model memiliki nilai praktis yang cukup signifikan, karena mampu memberikan setidaknya satu rekomendasi

yang relevan bagi sebagian pengguna. Secara keseluruhan, temuan ini memperkuat pentingnya keseimbangan antara akurasi dan eksplorasi dalam sistem rekomendasi, khususnya dalam konteks HR analytics di sektor kesehatan. Dari sisi praktis, model ini berpotensi membantu rumah sakit dalam meningkatkan kualitas pengambilan keputusan terkait pengembangan SDM yang lebih terarah dan berbasis kebutuhan nyata. Namun, penelitian ini masih memiliki beberapa keterbatasan, seperti penggunaan dataset dari satu institusi, bobot hybrid yang belum dioptimalkan secara adaptif, serta belum mempertimbangkan faktor kontekstual seperti beban kerja dan preferensi individu. Hal ini membuka peluang untuk pengembangan lebih lanjut di penelitian berikutnya.

REFERENCES

- [1] W. Cho, S. Choi, and H. Choi, "Human resources analytics for public personnel management: Concepts, cases, and caveats," *Administrative Sciences*, vol. 13, no. 2, p. 41, 2023. Available: <https://www.mdpi.com/2076-3387/13/2/41>
- [2] Q. Hossain and M. Z. Ikbali, "A meta data-driven decision support in human capital management: Reviewing HRIS and predictive analytics integration," *ASRC Procedia*, 2025. Available: <https://global.asrcconference.com/index.php/asrc/article/view/12>
- [3] Y. Chen, "Demand for digital and AI skills in healthcare: A NLP analysis of job listings in China," *Research Square*, 2025. Available: <https://www.researchsquare.com/article/rs-5867918/latest>
- [4] Y. Zhao, Y. Wang, Y. Liu, and X. Cheng, "Fairness and diversity in recommender systems: a survey," *ACM*, 2025, doi: 10.1145/3664928.
- [5] N. Rane, "Artificial intelligence-based recommendation systems for personalized and adaptive learning resources using learning analytics," *SSRN Electronic Journal*, 2026. Available: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=6372318
- [6] S. W. Yoon, S. Han, and C. Chae, "People analytics and human resource development: Research landscape and future needs based on bibliometrics and scoping review," *Human Resource Development Review*, 2024, doi: 10.1177/15344843231209362.
- [7] S. Naveen, M. S. Annapoorna, and V. Manimegalai, "Enhancing online employment analytics through deep learning-based predictive models," in *Advances in Data Analytics*, Springer, 2025, doi: 10.1007/978-3-032-04222-4_17.
- [8] M. Akter and A. Al Maruf, "Quantitative modeling of workforce forecasting using SQL-driven data pipelines and Power BI dashboards in predictive HR analytics," *Review of Applied Science and Technology*, 2025. Available: <https://rast-journal.org/index.php/RAST/article/view/26>
- [9] S. Nagarajan, H. Thangaraj, V. Vashisht, and E. Joshi, "A BERT-based hybrid recommendation system for academic collaboration," in *Springer*, 2024, doi: 10.1007/978-981-96-4273-1_9.
- [10] S. Kanwal, S. Nawaz, M. K. Malik, and Z. Nawaz, "A review of text-based recommendation systems," *IEEE Access*, 2021. Available: <https://ieeexplore.ieee.org/document/9354169>
- [11] K. Singh, S. Dhawan, and N. Bali, "An ensemble learning hybrid recommendation system using content-based and collaborative filtering," *Automatic Control and Computer Sciences*, 2024, doi: 10.3103/S0146411624700615.
- [12] S. Sarkar, "Development of a hybrid recommendation system using collaborative filtering and content-based filtering techniques," *IRE Journals*, 2025. Available: <https://www.academia.edu>
- [13] I. Saifudin and T. Widiyaningtyas, "Systematic literature review on recommender system: Approach, problem, evaluation techniques, datasets," *IEEE Access*, 2024. Available: <https://ieeexplore.ieee.org/document/10415424>
- [14] B. Akkaya, "Current trends in recommender systems: A survey of approaches and future directions," *Computer Science*, 2025. Available: <https://dergipark.org.tr/en/pub/bbd/issue/92233/1652022>
- [15] R. Burke, "Hybrid recommender systems: Survey and experiments," *User Modeling and User-Adapted Interaction*, vol. 12, no. 4, pp. 331–370, 2002, doi: 10.1023/A:1021240730564.
- [16] F. Ricci, L. Rokach, and B. Shapira, *Recommender Systems Handbook*. Springer, 2015.
- [17] G. Adomavicius and A. Tuzhilin, "Toward the next generation of recommender systems," *IEEE Transactions on Knowledge and Data Engineering*, vol. 17, no. 6, pp. 734–749, 2005, doi: 10.1109/TKDE.2005.99.
- [18] D. Jannach, M. Zanker, A. Felfelgig, and G. Friedrich, *Recommender Systems: An Introduction*. Cambridge University Press, 2010.
- [19] N. Sharma and M. Dutta, "Dynamic Ensemble Learning in Recommendation Systems: A Review," *Journal of Information & Knowledge*, 2026, doi: 10.1142/S0219649225501333.
- [20] Y. Yuan, Y. Zhou, X. Chen, Q. Xiong, and H. C. Okere, "Enhancing recommendation diversity and novelty," *Electronics*, vol. 13, no. 19, p. 3841, 2024. Available: <https://www.mdpi.com/2079-9292/13/19/3841>
- [21] T. Sachdeva, L. M. Goyal, and M. Mittal, "Mapping the landscape of personalization: A comprehensive review of recommendation systems," *WIREs Data Mining and Knowledge Discovery*, 2025, doi: 10.1002/widm.70006.
- [22] E. Hasan, M. Rahman, C. Ding, and J. X. Huang, "Recommender systems: A survey of approaches, challenges and future perspectives," *ACM Computing Surveys*, 2025, doi: 10.1145/3742421.
- [23] A. Jadon and A. Patil, "A comprehensive survey of evaluation techniques for recommendation systems," in *Springer*, 2024, doi: 10.1007/978-3-031-71484-9_25.
- [24] N. A. AlRossais, "Time-Evolving Fairness and Accuracy in Recommendation Systems," *IEEE Access*, 2025. Available: <https://ieeexplore.ieee.org/document/11186806>
- [25] R. Garapati and M. Chakraborty, "Recommender systems in the digital age: A comprehensive review of methods, challenges, and applications," *Knowledge and Information Systems*, 2025, doi: 10.1007/s10115-025-02453-y.
- [26] T. Bouwman, "Promoting Diversity while Tackling Popularity Bias," Utrecht University, 2025. Available: <https://studenttheses.uu.nl/handle/20.500.12932/50248>
- [27] D. Di Palma, G. M. Biancofiore, and V. W. Anelli, "Exploring Diversity, Novelty, and Popularity Bias in Recommendations," *arXiv preprint arXiv:2601.01997*, 2026. Available: <https://arxiv.org/abs/2601.01997>