



Systematic Literature Review: Tren dan Tantangan Machine Learning pada Sistem Rekomendasi Kursus Daring

Roni Habibi¹, Ryaas Ishlah Ramadhan²

^{1,2} Sekolah Vokasi, Sarjana Terapan Teknik Informatika, Universitas Logistik dan Bisnis Internasional

¹roni.habibi@ulbi.ac.id, ²ryaasishlah123@gmail.com

Abstract

This study presents a Systematic Literature Review (SLR) on the application of machine learning in online course recommendation systems. The aim is to map research trends, methodological approaches, and challenges in developing AI-based recommendation systems for online education. A total of 40 Scopus-indexed articles published between 2020 and 2025 were analyzed following the Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA 2020) guidelines, using the Watase UAKE tool for literature selection. The findings reveal that deep learning and hybrid models are the most dominant approaches, with a significant increase observed during 2022–2024. China contributes 57.5% of the studies, followed by India and Taiwan, indicating a strong research concentration in Asia. Combined architectures such as CNN–LSTM–ResNet achieved the highest accuracy (99.2%), while Reinforcement Learning (RL) and Deep Reinforcement Learning (DRL) are emerging as adaptive approaches for course recommendation. The main challenges identified include real-time adaptability, computational efficiency, and model transparency. The main contribution of this paper is to provide a comprehensive map of current research and outline future directions toward adaptive, efficient, and explainable online course recommendation systems.

Keywords: machine learning, course recommendation, deep learning, SLR, e-learning

Abstrak

Kajian ini menyusun Systematic Literature Review (SLR) mengenai penerapan machine learning dalam sistem rekomendasi kursus daring. Tujuan kajian ini adalah untuk memetakan tren, pendekatan metode, serta tantangan penelitian yang muncul dalam pengembangan sistem rekomendasi berbasis kecerdasan buatan di bidang pendidikan daring. Analisis dilakukan terhadap 40 artikel terindeks Scopus yang diterbitkan pada periode 2020–2025, dengan menggunakan panduan Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA 2020) dan bantuan alat Watase UAKE untuk proses seleksi literatur. Hasil peninjauan menunjukkan bahwa pendekatan deep learning dan hybrid model merupakan metode yang paling dominan digunakan, dengan peningkatan signifikan pada kurun waktu 2022–2024. Sebanyak 57,5% penelitian berasal dari Tiongkok, diikuti oleh India dan Taiwan, menunjukkan konsentrasi riset yang tinggi di kawasan Asia. Model gabungan seperti CNN–LSTM–ResNet menunjukkan akurasi tertinggi (99,2%), sedangkan pendekatan Reinforcement Learning (RL) dan Deep Reinforcement Learning (DRL) mulai banyak digunakan untuk sistem rekomendasi adaptif. Tantangan utama yang teridentifikasi meliputi adaptabilitas real-time, efisiensi komputasi, serta transparansi model dalam proses rekomendasi. Kontribusi utama studi ini adalah memberikan peta perkembangan riset terkini dan rekomendasi arah pengembangan menuju sistem rekomendasi kursus daring yang lebih adaptif, efisien, dan dapat dijelaskan (explainable).

Kata kunci: kata machine learning, rekomendasi kursus, deep learning, SLR, pendidikan daring.

1. Pendahuluan

Kemajuan teknologi informasi dan komunikasi telah membawa *transformasi* besar dalam dunia pendidikan, terkhusus pada platform pembelajaran daring seperti MOOC dan LMS yang memungkinkan akses *fleksibel* dan terbuka ke materi pembelajaran[1]. Model pembelajaran daring ini memungkinkan pembelajaran lebih adaptif dan dapat diakses oleh peserta didik dari berbagai [2], [3]. Namun, seiring berkembangnya jumlah kursus yang tersedia, tantangan baru muncul,

yaitu bagaimana memastikan peserta didik dapat mengakses konten yang sesuai dengan kebutuhan dan preferensi mereka. Sistem rekomendasi kursus daring menjadi solusi kunci untuk mengatasi masalah tersebut. Teknologi ini bertujuan untuk memberikan rekomendasi kursus yang dipersonalisasi, meningkatkan relevansi materi, serta membantu peserta didik memilih kursus yang paling sesuai dengan minat dan kebutuhan belajar mereka[4]. Pendekatan seperti *personalized course online recommendation* dan *course recommendation*



Lisensi

Lisensi Internasional Creative Commons Attribution-ShareAlike 4.0.

systems semakin banyak diterapkan untuk mendukung pengalaman belajar yang lebih efektif dan efisien[5].

Dalam pengembangan sistem rekomendasi yang efektif, berbagai metode telah diterapkan, mulai dari *collaborative filtering (CF)*, yang memanfaatkan pola interaksi antar pengguna, hingga *content-based filtering (CBF)*, yang menilai kesamaan fitur antara konten yang telah dipilih sebelumnya. Namun, meskipun kedua pendekatan ini memiliki potensi besar, keduanya memiliki kelemahan: *CF* seringkali mengalami masalah *cold-start* dan *sparsity*, sedangkan *CBF* cenderung menghasilkan rekomendasi yang terlalu sempit dan mengabaikan *diversitas* ilmu yang dimiliki pengguna [6], [7]. Untuk mengatasi masalah ini, pendekatan *hybrid* yang mengkombinasikan elemen *CF* dan *CBF* semakin banyak diterapkan. Pendekatan ini berpotensi menciptakan rekomendasi yang lebih baik dan lebih relevan bagi pengguna [8].

Untuk mengatasi kekurangan ini, pendekatan *hybrid* yang menggabungkan elemen *CF* dan *CBF* muncul sebagai solusi yang lebih efisien. Selain itu, dengan kemajuan teknologi *deep learning*, banyak sistem rekomendasi kini menggunakan pembelajaran mesin untuk menangkap pola yang lebih kompleks dalam data pengguna. Model *CNN*, *LSTM*, dan *ResNet* telah digunakan pada berbagai studi dan terbukti efektif dalam meningkatkan akurasi dan personalisasi rekomendasi [9]. Pendekatan berbasis *reinforcement learning* juga mulai digunakan untuk menciptakan sistem yang lebih adaptif terhadap perubahan preferensi pengguna secara dinamis [10], meningkatkan kemampuan sistem untuk memberikan rekomendasi yang lebih relevan dan terkini.

Kemajuan dalam teknologi *deep learning* telah membawa dampak besar terhadap sistem rekomendasi, dengan banyak sistem yang mulai memanfaatkan pembelajaran mesin untuk menangkap pola kompleks dalam data pengguna. Model-model seperti *Convolutional Neural Networks (CNN)*, *Long Short-Term Memory (LSTM)*, dan *Residual Networks (ResNet)* telah terbukti efisien dalam meningkatkan akurasi dan personalisasi rekomendasi [11], [12]. Selain itu, penerapan *reinforcement learning* dalam konteks ini memungkinkan sistem untuk menjadi lebih adaptif terhadap perubahan preferensi pengguna, sehingga meningkatkan relevansi rekomendasi yang disajikan [13], [14]. Meskipun demikian, tantangan teknis seperti masalah *cold-start* dan *sparsity* serta keterbatasan transparansi pada sistem berbasis *deep learning* yang sering dianggap sebagai *black-box* masih perlu diatasi untuk meningkatkan *interpretabilitas* dan *efektivitas* sistem rekomendasi tersebut [15], [16].

Sudah terdapat beberapa penelitian yang membahas topik sejenis antara lain dilakukan oleh [6], yang mengusulkan model *Bayesian* untuk rekomendasi kursus matematika, dan [17] yang menggabungkan *knowledge graph* dan *collaborative filtering* dalam

sistem rekomendasi terpersonalisasi[18], [19]. Selain itu, pendekatan *multimodal* seperti yang diajukan oleh [20] dalam merekomendasikan video kursus juga menjadi landasan relevan dalam domain ini.

Dalam konteks terkini, muncul pula isu baru terkait transparansi model (*explainability*) dan efisiensi komputasi. Banyak model berbasis *deep learning* yang bekerja sebagai “black box”, sehingga sulit dijelaskan proses pengambilan keputusannya. Selain itu, sistem rekomendasi adaptif menuntut kemampuan pemrosesan *real-time* yang efisien, namun belum banyak penelitian yang mengevaluasi aspek optimasi sumber daya dan waktu pelatihan pada sistem tersebut. Hal ini menandakan adanya *research gap* penting yang perlu dieksplorasi lebih lanjut agar sistem rekomendasi tidak hanya akurat, tetapi juga efisien dan transparan.

Berdasarkan permasalahan tersebut, kajian ini menyajikan sebuah *Systematic Literature Review (SLR)* untuk memetakan tren, pendekatan, dan tantangan penerapan *machine learning* dalam sistem rekomendasi kursus daring selama periode 2020–2025. Tujuan utama dari penelitian ini adalah untuk menjawab tiga pertanyaan penelitian: (1) Apa saja pendekatan dan model pembelajaran mesin yang paling umum digunakan dalam *course recommendation systems*, dan bagaimana dampaknya terhadap akurasi serta personalisasi? (2) Bagaimana tren penelitian dalam sistem rekomendasi kursus daring berkembang dalam lima tahun terakhir, ditinjau dari jumlah publikasi, wilayah geografis, dan area studi? (3) Apa saja gap riset serta arah pengembangan *course recommendation systems* yang lebih *adaptif*, *transparan*, dan *efisien* secara *komputasi* dalam konteks penerapan *deep learning*. Kontribusi utama penelitian ini adalah menyediakan peta komprehensif penelitian terkini yang dapat menjadi dasar bagi riset lanjutan dalam mengembangkan sistem rekomendasi kursus daring yang lebih adaptif, efisien, dan transparan [21], [22].

2. Metode Penelitian

Kajian ini mengeksplorasi penerapan pendekatan *machine learning* dalam sistem rekomendasi kursus daring, dengan penekanan pada pemanfaatan *model deep learning* dan *strategi hybrid*. Tujuan utama dari kajian ini adalah untuk mengkaji secara *sistematis model-model* rekomendasi yang telah digunakan, mengevaluasi tren dan distribusi penelitian selama lima tahun terakhir, serta menilai *efektivitas* pendekatan yang digunakan dalam mendukung personalisasi pembelajaran. Kajian ini juga bertujuan untuk mengidentifikasi berbagai tantangan dan potensi pengembangan sistem rekomendasi kursus daring yang lebih *adaptif* dan *efisien* dalam konteks pendidikan *digital*.

Metode yang digunakan dalam kajian ini adalah *Systematic Literature Review (SLR)*, yang merupakan pendekatan terstruktur dalam mengumpulkan,

menyeleksi, dan mensintesis hasil penelitian relevan. Pendekatan ini telah terbukti efektif dalam meminimalkan bias dalam analisis literatur dan mengidentifikasi tren penelitian yang berkembang. Dalam melaksanakan SLR, alat bantu *eksplorasi* literatur seperti *Watase UAKE* digunakan untuk mendukung proses pengumpulan dan analisis data [23].

Kajian ini juga sejalan dengan penelitian sistematis oleh Najmani et al. (2022) yang meninjau 123 artikel tentang sistem rekomendasi MOOCs dari lima basis data besar dan mengelompokkan fokus riset ke dalam enam bidang utama. Studi tersebut memperkuat relevansi pendekatan sistematis dalam memahami tren dan arah penelitian sistem rekomendasi pembelajaran daring [24].

Dalam proses pelaksanaannya, SLR ini didukung oleh perangkat bantu eksplorasi literatur *Watase UAKE* (*Watase Literature Exploration Tools*), yang berfungsi dalam proses pencarian, klasifikasi, dan *visualisasi data* literatur. Proses pencarian artikel dilakukan melalui *basis data Scopus*, dengan menggunakan kata kunci seperti: *Course Online Recommendation*, *Personalized Course Online Recommendation*, *Personalized Online Learning Recommendation*, *Review Course Recommendation*, *Course Recommendation Systems*, dan *Personalized Course Recommendation System*. Ruang lingkup pencarian dibatasi pada publikasi yang terbit antara tahun 2020 hingga 2025, serta difokuskan pada artikel ilmiah yang telah terindeks secara resmi.

Untuk menjaga kualitas literatur yang dianalisis, digunakan kriteria validitas berupa: (a) artikel harus terindeks Scopus, (b) terbit pada rentang 2020–2025, (c) ditulis dalam bahasa Inggris, (d) memiliki akses teks lengkap, dan (e) termasuk dalam jurnal dengan kuartil Q1–Q4 berdasarkan peringkat Scimago Journal Rank (SJR). Selain itu, tingkat sitasi dan relevansi terhadap topik penelitian turut dipertimbangkan dalam proses pemilihan akhir.

Tabel 1 Distribusi Publikasi Kategori

No	Kategori	Jumlah
1	Q1	14
2	Q2	11
3	Q3	9
4	Q4	6
Total		40

Distribusi ini menunjukkan bahwa sebagian besar literatur yang disertakan dalam kajian berasal dari jurnal bereputasi tinggi (Q1 dan Q2), sehingga meningkatkan keandalan dan validitas hasil sintesis data.

Sintesis data dilakukan menggunakan analisis tematik (*thematic analysis*) dan analisis deskriptif (*descriptive analysis*). Analisis tematik digunakan untuk mengelompokkan artikel berdasarkan fokus penelitian, jenis algoritma *machine learning*, serta konteks penerapan sistem rekomendasi. Sementara itu, analisis deskriptif digunakan untuk menampilkan distribusi publikasi berdasarkan tahun, negara asal penulis, desain

penelitian, serta tingkat kuartil jurnal. Pendekatan kombinatorik ini memungkinkan peneliti untuk mengidentifikasi pola, tren, dan kesenjangan riset yang muncul secara komprehensif.

Tahap *identification* bertujuan untuk menjangkau artikel-artikel yang relevan dengan topik penelitian berdasarkan kata kunci yang telah ditentukan. Hasil pencarian awal menghasilkan sebanyak 159 artikel dari *basis data Scopus*. Dari jumlah tersebut, dilakukan penghapusan terhadap 24 artikel *duplikat*, 29 artikel yang terbit di luar tahun yang ditetapkan, serta 6 artikel yang tidak berasal dari jurnal dengan peringkat Q1–Q4. Sehingga, tersisa 100 artikel yang kemudian disaring lebih lanjut.

Pada tahap *screening*, seleksi dilakukan dengan meninjau abstrak dan judul artikel. Sebanyak 22 artikel dikeluarkan karena dinilai tidak sesuai dengan fokus kajian. Sisanya, yaitu 78 artikel, masuk ke tahap pemeriksaan dokumen lengkap, namun 39 artikel di antaranya tidak tersedia dalam versi *full-text* sehingga tidak dapat dianalisis lebih lanjut.

Selanjutnya, tahap *eligibility* dilakukan untuk menilai kecocokan isi artikel secara menyeluruh. Dari hasil peninjauan, sebanyak 40 artikel — terdiri atas 39 artikel dari Scopus dan 1 artikel dari sumber eksternal lain — dinyatakan memenuhi semua kriteria seleksi.

Tahap akhir adalah *included*, yaitu tahap di mana seluruh artikel yang lolos seleksi dikaji secara mendalam dan dijadikan dasar dalam proses analisis tematik. Artikel-artikel ini menjadi rujukan utama dalam menjawab pertanyaan penelitian yang telah dirumuskan, serta dalam mengidentifikasi arah strategis untuk pengembangan sistem rekomendasi pembelajaran daring berbasis kecerdasan buatan di masa mendatang.

3. Hasil dan Pembahasan

Kajian ini bertujuan untuk mengidentifikasi pendekatan dan model pembelajaran mesin yang umum digunakan dalam sistem rekomendasi kursus daring, meninjau tren penelitian yang berkembang selama lima tahun terakhir, serta mengeksplorasi gap riset dan arah pengembangan sistem yang *adaptif*, *transparan*, dan efisien secara komputasi. Pendekatan yang digunakan adalah *systematic literature review (SLR)* berbasis protokol *PRISMA*, dengan proses identifikasi, penyaringan, dan analisis artikel dilakukan menggunakan bantuan platform eksplorasi literatur *Watase UAKE*. Hasil yang diperoleh dari proses seleksi hingga sintesis data akan disajikan secara bertahap berdasarkan kategori *visualisasi* dan *klasifikasi tematik* dari literatur yang dianalisis.

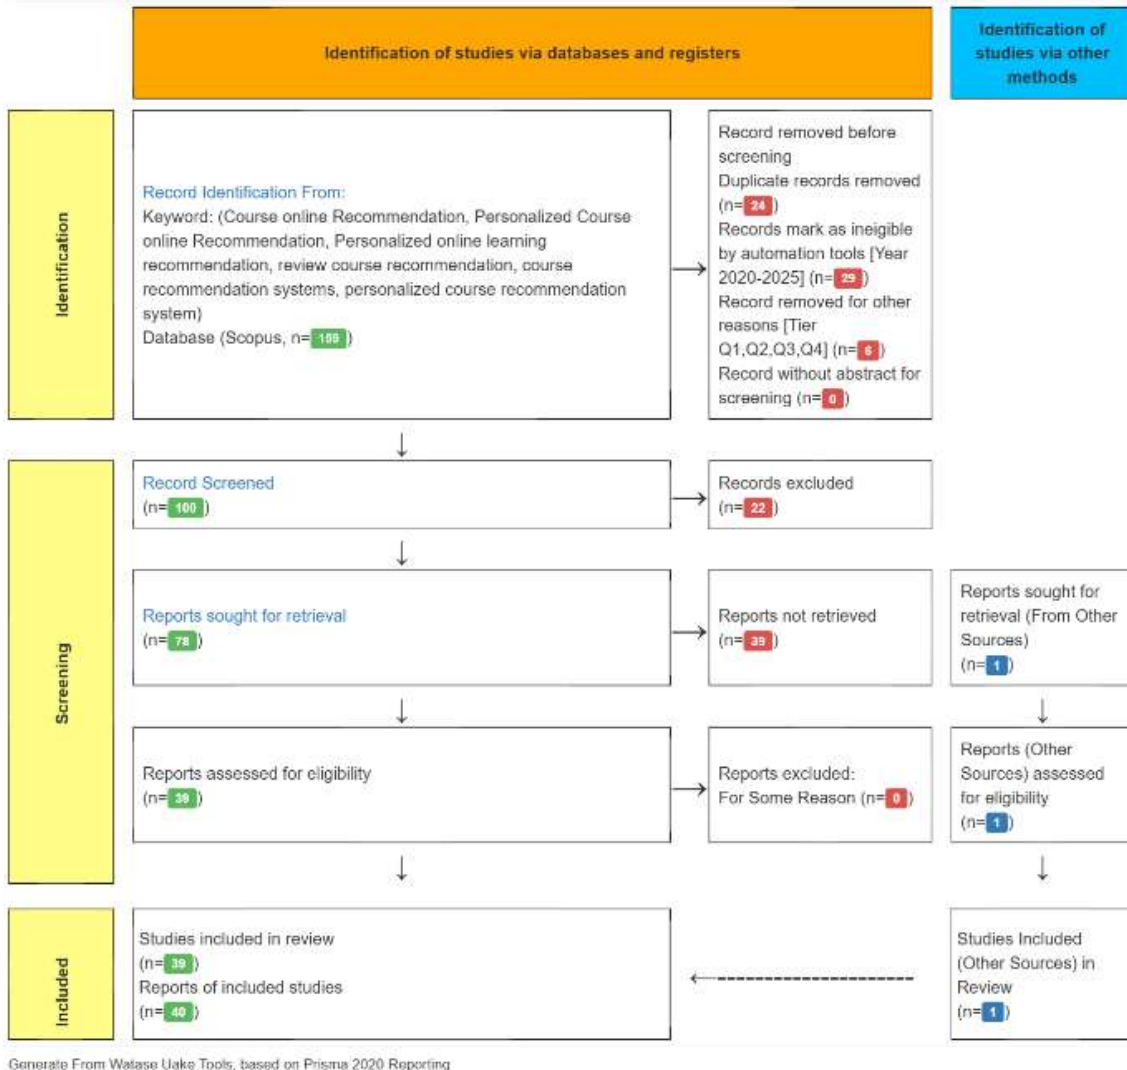
3.1. Hasil

Gambar 1 menunjukkan diagram *PRISMA* yang menggambarkan proses seleksi artikel secara sistematis dalam studi ini. Dari total 159 artikel yang ditemukan melalui *database Scopus*, sebanyak 24 artikel dihapus

karena duplikasi, 29 artikel dieliminasi karena berada di luar rentang tahun publikasi 2020–2025, dan 6 artikel tidak memenuhi kriteria kualitas jurnal. Sebanyak 100 artikel dilanjutkan ke tahap penyaringan berdasarkan judul dan abstrak, namun 22 di antaranya dikeluarkan

karena tidak relevan. Dari 78 artikel yang diperiksa lebih lanjut, 39 tidak tersedia dalam *full-text*. Akhirnya, 39 artikel dari Scopus dan 1 artikel tambahan dari sumber lain dinyatakan layak dan dimasukkan ke dalam analisis sistematis.


Prisma Reporting: Recommendation Course Online (ryaas)




Gambar 1. Prisma Diagram

Gambar 2 memperlihatkan tren publikasi selama lima tahun terakhir. Peningkatan jumlah artikel dari tahun ke tahun menunjukkan adanya pertumbuhan signifikan dalam ketertarikan peneliti terhadap topik sistem rekomendasi pembelajaran daring, terutama setelah masa pandemi COVID-19. Menurut [25], lonjakan adopsi *platform* daring mendorong pengembangan sistem personalisasi untuk meningkatkan keterlibatan belajar. Gambar 3 menunjukkan *distribusi geografis* artikel yang dikaji. China menjadi *kontributor dominan* dengan 57,5% dari total studi, yang mencerminkan kuatnya *ekosistem riset* dan ketersediaan data pendidikan *digital* berskala besar di negara tersebut. India menyumbang 12,5%, diikuti oleh negara-negara lain seperti Taiwan, Spanyol, Inggris, Norwegia,


Belanda, dan Amerika Serikat. Dominasi artikel dari China mencerminkan tren yang juga ditemukan oleh [26], yang menekankan bahwa ketersediaan dataset berskala besar di negara tersebut mendorong inovasi sistem rekomendasi. Dalam hal pendekatan metodologis, Gambar 4 mengilustrasikan bahwa sebagian besar artikel (82,5%) menggunakan metode eksperimental, menandakan bahwa *validasi model* secara langsung menjadi fokus utama penelitian. Studi kasus mencakup 10%, sementara *systematic review* dan survey masing-masing berkontribusi 5% dan 2,5%. Menurut [5], pendekatan ini penting untuk menguji efektivitas model secara nyata, khususnya dalam konteks rekomendasi berbasis perilaku pengguna.



Gambar 2. Tahun Publikasi




Gambar 3. Negara Asal Dataset




Gambar 4. Metode

Gambar 5 menyajikan *distribusi area studi* utama dari literatur yang dikaji. Sebanyak 77,5% artikel berasal dari *domain educational technology*, diikuti oleh *learning analytics* (7,5%) dan *systematic literature review* (5%). [9] juga menekankan bahwa pendekatan seperti *CNN* dan *LSTM* banyak dikembangkan dalam kerangka teknologi pendidikan untuk meningkatkan akurasi sistem rekomendasi.

Gambar 6 menunjukkan bahwa pendekatan prediksi merupakan metode analisis yang paling banyak digunakan (58,3%), diikuti oleh klasifikasi (27,8%), optimisasi (11,1%), dan regresi (3%). Ini menunjukkan bahwa sebagian besar studi bertujuan membangun model prediktif yang mampu merekomendasikan konten pembelajaran secara relevan berdasarkan preferensi atau interaksi pengguna.




Gambar 5. Distribusi Area Studi



Gambar 6. Jenis Metode Analisis

Gambar 7 memperlihatkan hasil *word cloud* dari ekstraksi variabel, di mana terlihat bahwa sebagian besar studi menekankan pada aspek teknis dan struktural dalam membangun sistem rekomendasi. Beberapa yang dikembangkan cenderung menggabungkan istilah yang dominan seperti *course recommendations*, *representasi data berbasis vektor* dengan arsitektur *word vectors from course data*, *course recommendation accuracy*, *performance evaluation of recommendation models*, serta *hybrid deep learning model (CNN, ResNet, LSTM)* menunjukkan bahwa model-model rekomendasi pembelajaran mendalam untuk meningkatkan akurasi

dan relevansi rekomendasi [27], [28]. Istilah lain seperti *layer multi-head attention*, *use of CRF layer*, dan *user preferences* juga menandakan penggunaan fitur lanjutan dalam pemodelan jaringan *neural* serta *integrasi data* preferensi pengguna dalam proses pelatihan *model*.



Gambar 7. Variabel Wordcloud

Sementara itu, Gambar 8 menampilkan *word cloud* dari *metadata* artikel yang diambil dari *database Scopus*. Visualisasi ini memperlihatkan jangkauan konsep yang lebih luas dan bersifat *multidisipliner*. Istilah-istilah seperti *e-learning*, *deep learning*, *reinforcement learning*, *online learning*, *personalized recommendation*, dan *recommendation system* menandakan bahwa fokus utama dari literatur berada pada pengembangan sistem adaptif berbasis *AI* untuk mendukung pembelajaran daring yang personal. Selain itu, kemunculan istilah seperti *learner behavior*, *learning communities*, *online education*, *artificial intelligence*, dan *feedback data* mencerminkan bahwa faktor interaksi pengguna, dinamika sosial dalam pembelajaran, serta analisis perilaku belajar turut menjadi perhatian penting dalam desain sistem rekomendasi yang kontekstual dan berkelanjutan.

Gambar 9 menunjukkan bahwa hipotesis yang paling sering diajukan dalam literatur berkaitan dengan hubungan antara *Word Vectors From Course Data* dan efektivitas *Personalized Course Resource Recommendations*. Menurut [29], representasi berbasis vektor seperti *word embeddings* dan pemetaan semantik penting untuk meningkatkan ketepatan rekomendasi pada platform pembelajaran daring. Selain itu, penelitian oleh [30] dan [20] juga mendemonstrasikan efektivitas

pemanfaatan kombinasi teknik *CNN*, *ResNet*, dan *LSTM* dalam merancang model *hibrida* berbasis konten dan perilaku pengguna. Pendekatan seperti *CRF layer* dan *multi-head attention* juga muncul dalam studi oleh [31] sebagai inovasi dalam pengolahan data urut dan kontekstual. Menurut [29], representasi berbasis vektor seperti *word embeddings* dan pemetaan semantik penting untuk meningkatkan ketepatan rekomendasi pada platform pembelajaran daring.

Selanjutnya, Gambar 10 memperkuat bahwa tidak ada variabel dominan dalam semua studi. Namun, keberagaman ini mencerminkan bahwa komunitas riset sedang mengeksplorasi berbagai teknik untuk meningkatkan personalisasi dan relevansi. Seperti dijelaskan oleh [32], kompleksitas variabel yang digunakan seperti *prediction score*, *ranking list*, dan *embedding struktural* menunjukkan adanya orientasi eksploratif yang kuat. Penelitian oleh [28] juga menekankan pentingnya pemanfaatan kombinasi variabel teknis dan *metadata* pengguna untuk membangun sistem yang lebih adaptif dan kontekstual. Namun, keberagaman ini mencerminkan bahwa komunitas riset sedang mengeksplorasi berbagai teknik untuk meningkatkan personalisasi dan relevansi.



Gambar 8. Metadata Worldcloud



Gambar 9. Grafik Hipotesis



Gambar 10. Grafik Variabel

Secara keseluruhan, hasil ini menunjukkan bahwa lanjut pada aspek *efisiensi* dan *adaptabilitas* sistem. penelitian sistem rekomendasi kursus daring dalam lima tahun terakhir didominasi oleh pendekatan eksperimental berbasis *deep learning*, dengan fokus utama pada peningkatan personalisasi dan relevansi konten. Kontribusi riset didominasi oleh wilayah Asia, khususnya China dan India, dengan fokus utama pada teknologi pendidikan. Kajian ini juga memperlihatkan bahwa topik sistem rekomendasi kursus daring telah berkembang ke arah *integrasi pendekatan kompleks*, namun masih terdapat ruang untuk *eksplorasi* lebih

Tabel 2. Tabel Komparatif

No	Model Algoritma	Jenis Pendekan	Evaluasi Metrik	Gap dan Arah Penelitian
[33]	IRS-GCNet	Deep Learning	Precision 43.92	Perlu <i>efisiensi</i> pelatihan dan pengembangan struktur <i>graph</i> yang dinamis.
[32]	RP-CFGAN	Deep Learning	Accuracy 0.4418	<i>Optimalisasi</i> arsitektur, privasi pengguna, dan <i>integrasi</i> pada sistem IoT.
[34]	RecBC + BiLSTM + RL	Deep Learning	Accuracy 91.9%, NDCG 60.13	<i>Eksplorasi</i> preferensi <i>granular</i> dalam perilaku pembelajaran.
[35]	DRR (Actor-Critic DRL)	Deep Learning	Accuracy 75.64%, Precision 71.24%, Recall 76.53%, NDCG 60.03	<i>Eksplorasi</i> lanjut pada Double DQN dan DDPG untuk <i>efisiensi</i> dan <i>adaptivitas</i> .
[36]	MetaFTGRec	Deep Learning	Accuracy 0.613, F1 0.871, NDCG 0.956	Evaluasi lebih lanjut pada sistem pendidikan lain.
[37]	Actor-Critic RL (MOOCERS)	Reinforcement Learning	NDCG 0.684	<i>Integrasi</i> NLP dan penggunaan <i>reward alternatif</i> .
[9]	Hybrid CNN + ResNet + LSTM	Deep Learning	Accuracy 99.20%, Precision 99.40%, Recall 99.20%, F1 99.10	Validasi lebih lanjut pada dataset <i>berskala</i> besar dalam LMS.
[38]	KT_Transformers	Deep Learning	Recall 0.073, NDCG 0.244	Uji pada platform berbeda dan peningkatan <i>explainability</i> .
[29]	Modified Elo-rating	Machine Learning	Precision 0.65, Recall 0.62	Perbandingan dengan pendekatan IRT dan <i>eksplorasi gamifikasi</i> .
[39]	Autoencoder + LSTM + Attention	Deep Learning	Precision 0.2748, Recall 0.2819, F1 0.1857	Evaluasi pada data kompleks dan <i>heterogen</i> .
[17]	FKGCF	Hybrid	Precision 22.5, Recall 20, F1 8	<i>Integrasi model time-series</i> untuk prediksi <i>temporal</i> .
[40]	Ontology + Trust + ML	Hybrid	Precision 98.2, Recall 96, F1 0.28	Perluasan <i>ontologi</i> ke domain dan konteks lain.
[25]	User-CF + LR + FM	Hybrid	Accuracy 81.3, Recall 79.2, F1 80.2	<i>Eksplorasi</i> model <i>non-linear</i> dan analisis perilaku pengguna.

Secara umum, *model* berbasis *deep learning* pembelajaran. *Model* seperti Hybrid CNN + ResNet + LSTM [9] menunjukkan *performa* sangat tinggi dalam menangkap representasi kompleks dari data metrik klasifikasi. Di sisi lain, pendekatan berbasis

struktur *graf* seperti *IRS-GCNet* [17] dan *model generatif* seperti *RP-CFGAN* [25] memperkenalkan inovasi arsitektur meskipun masih menghadapi tantangan seperti *noise* dan *cold-start*.

Beberapa pendekatan *hybrid* seperti *User-CF + LR + FM* [28] dan *Ontology + Trust + ML* [40] terbukti kompetitif dalam mengatasi permasalahan distribusi data dan personalisasi pengguna. Selain itu, *model Modified Elo-rating* [29] dan *FKGCF* [41] mengusung prinsip pemetaan semantik dan sistem penilaian dinamis untuk meningkatkan relevansi rekomendasi.

Pendekatan *reinforcement learning* juga mulai menunjukkan potensi besar dalam *adaptivitas* sistem. *Model* seperti *DRR* [10] dan *MOOCERS* [25] menunjukkan bahwa penggunaan *reward* dinamis mampu meningkatkan kemampuan sistem dalam menyesuaikan diri dengan perubahan preferensi pengguna. Selain itu, [35] menegaskan pentingnya optimasi efisiensi komputasi agar sistem dapat diimplementasikan secara luas di lingkungan dunia nyata.

Hasil keseluruhan menunjukkan bahwa penelitian lima tahun terakhir didominasi oleh pendekatan *deep learning* (42,5%) dan *hybrid learning* (30%), diikuti oleh metode klasik seperti *SVM* dan *Decision Tree*. Meskipun hasil metrik seperti akurasi dan *F1-score* menunjukkan peningkatan signifikan, tantangan terbesar masih terletak pada efisiensi komputasi dan *explainability*. Selain itu, muncul tren baru berupa penerapan *Reinforcement Learning (RL)* dan *Deep Reinforcement Learning (DRL)*, khususnya *Actor-Critic* dan *DQN*, yang berpotensi menghasilkan sistem rekomendasi adaptif dan responsif terhadap perubahan preferensi pengguna. Temuan ini menunjukkan adanya pergeseran fokus riset ke arah model yang lebih kompleks, efisien, dan transparan, sejalan dengan arah pengembangan *Explainable AI (XAI)*.

Temuan ini sejalan dengan hasil tinjauan terbaru oleh Dhananjaya et al. (2024) yang menegaskan pergeseran riset menuju integrasi *deep learning*, *reinforcement learning*, serta teknologi digital baru seperti *Fluxy AI* dan *Twin Technology* untuk meningkatkan personalisasi dan adaptivitas sistem rekomendasi pembelajaran daring [42].

Berdasarkan analisis tematik (*thematic analysis*), terdapat tiga tema utama yang mengemuka: (1) optimalisasi model dan arsitektur untuk meningkatkan performa rekomendasi, (2) pengembangan sistem rekomendasi adaptif melalui integrasi *reinforcement learning*, serta (3) peningkatan efisiensi komputasi dan transparansi model. Implikasi dari temuan ini adalah perlunya penelitian lanjutan yang mengeksplorasi strategi optimasi sumber daya komputasi, integrasi model ringan (*model compression*), dan penggunaan *explainable frameworks* untuk meningkatkan kepercayaan pengguna terhadap hasil rekomendasi.

Secara keseluruhan, tabel ini memperlihatkan bahwa sistem rekomendasi kursus daring terus berkembang menuju pendekatan yang lebih kompleks dan adaptif. Meskipun performa metrik seperti *accuracy*, *precision*, dan *NDCG* menunjukkan hasil yang menjanjikan, masih terdapat kebutuhan untuk mengatasi keterbatasan teknis dan memperluas ruang *eksplorasi* terhadap integrasi *model*, keterlibatan pengguna, serta aspek penjelas (*explainability*) dalam pengambilan keputusan sistem. Temuan ini menjadi dasar penting bagi pengembangan penelitian lanjutan di bidang teknologi rekomendasi pendidikan.

3.2. Pembahasan

RQ1 Apa saja pendekatan dan model pembelajaran mesin yang paling umum digunakan dalam sistem rekomendasi kursus daring, dan bagaimana dampaknya terhadap akurasi serta personalisasi rekomendasi?

Berdasarkan hasil sintesis dari Tabel 1, pendekatan berbasis *deep learning* merupakan metode yang paling umum digunakan dalam pengembangan sistem rekomendasi kursus daring. *Model-model* seperti *CNN*, *BiLSTM*, dan *DNN* menunjukkan performa tinggi dalam hal akurasi dan personalisasi. Misalnya, *model Hybrid CNN + ResNet + LSTM* mencapai akurasi 99,20% dan *F1-score* 99,10% [9]. Pendekatan *hybrid* yang menggabungkan teknik *collaborative filtering*, *content-based filtering*, dan *deep learning* seperti *Ontology + Trust + ML* juga menunjukkan hasil kompetitif [40]. Sementara itu, pendekatan tradisional seperti *Modified Elo-rating* masih diterapkan dalam skenario terbatas, namun dengan efektivitas yang relatif lebih rendah [29]. Temuan ini memperkuat bahwa model berbasis *deep learning* dan *hybrid* saat ini menjadi pendekatan utama dalam meningkatkan kualitas rekomendasi yang personal.

RQ2 Bagaimana tren penelitian dalam sistem rekomendasi kursus daring berkembang dalam lima tahun terakhir, ditinjau dari jumlah publikasi, wilayah geografis, dan area studi?

Tren publikasi menunjukkan pertumbuhan signifikan, sebagaimana ditunjukkan pada Gambar 2, dengan peningkatan publikasi sejak 2020 dan puncaknya pada 2022. Secara geografis, China mendominasi publikasi (Gambar 3), didorong oleh ketersediaan dataset berskala besar dan perhatian nasional terhadap teknologi pendidikan [26]. Di sisi metodologi, Gambar 4 memperlihatkan bahwa pendekatan eksperimental mendominasi (82,5%), yang sejalan dengan kebutuhan validasi langsung terhadap performa sistem [5]. *Domain* penelitian pun mayoritas berasal dari *educational technology* (Gambar 5), mendukung keterkaitan erat antara teknologi pembelajaran dan personalisasi *digital* [9]. Selain itu, Gambar 6 menunjukkan bahwa metode prediksi menjadi teknik analitik yang paling banyak digunakan, mendukung kecenderungan riset terhadap model prediktif berbasis perilaku pengguna [10].

RQ3 Apa saja gap riset dan arah pengembangan masa depan dalam menciptakan sistem rekomendasi yang adaptif secara real-time, dapat dijelaskan kepada pengguna, dan efisien secara komputasi, khususnya dalam konteks penerapan model deep learning?

Tabel 1 memperlihatkan bahwa meskipun pendekatan *deep learning* mendominasi, mayoritas *model* masih bersifat *statis* dan belum sepenuhnya *adaptif* terhadap *dinamika* preferensi pengguna. Tantangan yang muncul meliputi keterbatasan pada aspek *interpretabilitas*, kebutuhan komputasi tinggi, serta kurangnya fokus pada *fairness* dalam sistem rekomendasi. Studi oleh [35] menggarisbawahi pentingnya efisiensi komputasi dan *interpretabilitas* agar model dapat diimplementasikan secara luas dan transparan. *Model berbasis reinforcement learning* seperti *DRR (Actor-Critic)* telah menunjukkan potensi dalam mengakomodasi perubahan perilaku pengguna secara *real-time*, dan membuka arah baru pengembangan sistem berbasis *Double DQN* dan *DDPG* yang lebih efisien secara komputasi.

Menariknya, pendekatan *Deep Reinforcement Learning (DRL)* mulai menunjukkan potensi besar dalam pengembangan sistem rekomendasi kursus daring yang *adaptif*. Salah satu *model* yang menonjol adalah *DRR (Actor-Critic DRL)*, yang mencatat *accuracy* 75,64%, *precision* 71,24%, *recall* 76,53%, dan *NDCG* 60,03. Selain itu, pendekatan lain seperti *MOOCERS (Actor-Critic + NLP)* turut memperluas kemampuan adaptasi dengan memanfaatkan analisis bahasa alami untuk meningkatkan konteks rekomendasi, serta menunjukkan performa *NDCG* sebesar 0.684. Studi-studi ini menegaskan bahwa pendekatan *DRL*, khususnya arsitektur *actor-critic*, merupakan fondasi kuat untuk membangun sistem rekomendasi yang responsif dan berkelanjutan.

Selain model-model tersebut, *integrasi reinforcement learning* dengan arsitektur *deep learning* lainnya juga memberikan kontribusi yang signifikan. *Model* seperti *RecBC + BiLSTM + RL* mencapai *accuracy* 91,9% dan *NDCG* 60,13 dengan menekankan pada pemodelan urutan perilaku pengguna secara *granular*, sementara pendekatan *KT_Transformers* mulai mengeksplorasi integrasi antara mekanisme *attention* dan metode *RL* untuk meningkatkan *explainability*, meskipun performa masih terbatas (*recall* 0.073, *NDCG* 0.244). Temuan ini menunjukkan bahwa pengembangan sistem rekomendasi ke depan perlu difokuskan pada optimalisasi adaptivitas, efisiensi komputasi, serta kemampuan penjelasan sistem terhadap pengguna, untuk mendukung personalisasi pembelajaran yang lebih kontekstual dan transparan.

4. Kesimpulan

Studi ini secara sistematis mengevaluasi perkembangan sistem rekomendasi kursus daring berbasis *machine learning* dalam lima tahun terakhir melalui pendekatan

Systematic Literature Review (SLR). Sebanyak 40 artikel primer terindeks Scopus dianalisis untuk menjawab tiga pertanyaan utama, yaitu: (1) pendekatan dan model pembelajaran mesin yang umum digunakan, (2) tren penelitian berdasarkan publikasi, wilayah, dan area studi, serta (3) arah pengembangan sistem yang adaptif, efisien, dan transparan. Berdasarkan hasil klasifikasi kuartil, 35% artikel berasal dari jurnal Q1, 27,5% dari Q2, 22,5% dari Q3, dan 15% dari Q4, menunjukkan bahwa mayoritas literatur memiliki kualitas publikasi yang tinggi. Selain itu, pendekatan *deep learning* mendominasi 42,5% dari keseluruhan studi, disusul oleh *hybrid learning* (30%) dan algoritma klasik seperti *Random Forest* dan *Decision Tree*.

Pertama, hasil kajian menunjukkan bahwa pendekatan berbasis *deep learning*, khususnya *model CNN*, *BiLSTM*, dan *ResNet*, menjadi yang paling dominan diterapkan dalam sistem rekomendasi kursus daring. Beberapa studi juga mengadopsi pendekatan *hybrid* yang menggabungkan *collaborative filtering*, *content-based filtering*, dan *deep learning*. Model-model ini menunjukkan performa tinggi, dengan akurasi dan *F1-score* melebihi 90% dalam sebagian besar kasus, menandakan kemampuannya dalam menangkap preferensi pengguna secara lebih mendalam dan personal. Kedua, tren penelitian menunjukkan peningkatan jumlah publikasi yang stabil dari tahun 2020 hingga 2024. Secara geografis, kontribusi terbesar berasal dari China dan India, sementara mayoritas artikel berasal dari area *educational technology*. Dominasi pendekatan eksperimental sebesar 82,5% menegaskan bahwa evaluasi model secara langsung menjadi strategi yang paling umum digunakan dalam validasi sistem. Ketiga, beberapa studi mulai mengeksplorasi pendekatan *Deep Reinforcement Learning (DRL)*, khususnya *model Actor-Critic*, sebagai solusi terhadap tantangan adaptabilitas *real-time* dan personalisasi berbasis perilaku. Studi *DRR (Actor-Critic DRL)*, misalnya, menunjukkan metrik evaluatif kompetitif dengan *accuracy* 75,64%, *precision* 71,24%, dan *NDCG* 60,03. Arah pengembangan ke model lanjutan seperti *Double DQN* dan *DDPG* menandai pergeseran fokus penelitian menuju sistem yang tidak hanya akurat, tetapi juga efisien dan responsif terhadap dinamika pengguna.

Secara keseluruhan, hasil SLR ini menegaskan bahwa pengembangan sistem rekomendasi kursus daring bergerak menuju integrasi model yang lebih kompleks, adaptif, dan transparan, dengan penekanan pada efisiensi komputasi serta keterjelasan proses rekomendasi (*explainability*). Oleh karena itu, penelitian selanjutnya disarankan untuk memfokuskan perhatian pada optimalisasi arsitektur model yang hemat sumber daya, integrasi pendekatan *reinforcement learning* adaptif, dan penerapan *explainable AI (XAI)* agar sistem tidak hanya unggul secara performa, tetapi juga dapat dipercaya dan mudah dipahami oleh pengguna. Temuan ini diharapkan dapat menjadi landasan konseptual dan empiris bagi riset

lanjutan dalam pengembangan sistem rekomendasi pembelajaran digital yang lebih cerdas, efisien, dan kontekstual.

Daftar Rujukan

- [1] N. Preston *et al.*, "Disseminating research findings using a massive online open course for maximising impact and developing recommendations for practice," *BMC Palliat Care*, vol. 19, no. 1, Apr. 2020, doi: 10.1186/s12904-020-00564-7.
- [2] Y. Zheng, J. Miao, and S. Ren, "Intelligent Recommendation System for Personalized Learning Resources for College Students Based on Image Processing," *Traitement Du Signal*, 2024, doi: 10.18280/ts.410127.
- [3] L. Yang, Y. Yu, and Y. Wei, "Data-Driven Artificial Intelligence Recommendation Mechanism in Online Learning Resources," *International Journal of Crowd Science*, 2022, doi: 10.26599/ijcs.2022.9100020.
- [4] H. Abu-Rasheed, C. Weber, and M. Fathi, "Context Based Learning: A Survey of Contextual Indicators for Personalized and Adaptive Learning Recommendations – A Pedagogical and Technical Perspective," *Front Educ (Lausanne)*, 2023, doi: 10.3389/feduc.2023.1210968.
- [5] X. Chen and H. Deng, "Research on personalized recommendation methods for online video learning resources," *Applied Sciences (Switzerland)*, vol. 11, no. 2, pp. 1–11, Jan. 2021, doi: 10.3390/app11020804.
- [6] S. Li, H. Chen, X. Liu, J. Li, K. Peng, and Z. Wang, "Online Personalized Learning Path Recommendation Based on Saltatory Evolution Ant Colony Optimization Algorithm," *Mathematics*, 2023, doi: 10.3390/math11132792.
- [7] X. Shuoyan, "Recommendation of Online Learning Resources for Personalized Fragmented Learning Based on Mobile Devices," *International Journal of Emerging Technologies in Learning (Ijet)*, 2022, doi: 10.3991/ijet.v17i03.29427.
- [8] D. Banik, S. C. Satapathy, and M. Agarwal, "Advanced Weighted Hybridized Approach for Recommendation System," *International Journal of Web Information Systems*, 2023, doi: 10.1108/ijwis-01-2022-0006.
- [9] S. Subha, B. P. Sankaralingam, A. Gurusamy, S. Sehar, and D. P. Bavirisetti, "Personalization-based deep hybrid E-learning model for online course recommendation system," *PeerJ Comput Sci*, vol. 9, 2023, doi: 10.7717/peerj-cs.1670.
- [10] W. Intayoad, C. Kamyod, and P. Temdee, "Reinforcement Learning Based on Contextual Bandits for Personalized Online Learning Recommendation Systems," *Wirel Pers Commun*, vol. 115, no. 4, pp. 2917–2932, Dec. 2020, doi: 10.1007/s11277-020-07199-0.
- [11] Q. Zhang, Y. Liu, L. Liu, S. Lü, Y. Feng, and Y. Xiao, "Location Identification and Personalized Recommendation of Tourist Attractions Based on Image Processing," *Traitement Du Signal*, 2021, doi: 10.18280/ts.380121.
- [12] X. Qi, J. Zhao, and G. Hu, "Explore the Personalized Resource Recommendation of Educational Learning Platforms: Deep Learning," *Informatica*, 2024, doi: 10.31449/inf.v48i7.5690.
- [13] Y. Sun, J. Zhou, M. Ji, L. Pei, and Z. Wang, "Development and Evaluation of Health Recommender Systems: Systematic Scoping Review and Evidence Mapping," *J Med Internet Res*, 2023, doi: 10.2196/38184.
- [14] T. Gu, H. Liang, C. Bin, and L. Chang, "Combining User-End and Item-End Knowledge Graph Learning for Personalized Recommendation," *Journal of Intelligent & Fuzzy Systems*, 2021, doi: 10.3233/jifs-201635.
- [15] C. Caroline, O. Oroh, and D. Pada, "Enhancing Online Learning Experiences Through Personalization Utilizing Recommendation Algorithms," *International Journal Software Engineering and Computer Science (Ijsecs)*, 2023, doi: 10.35870/ijsecs.v3i3.1852.
- [16] C.-Z. Tsai, H. Huang, C.-J. Wei, and M. Chiu, "Apply Deep Learning to Build a Personalized Attraction Recommendation System in a Smart Product Service System," 2023, doi: 10.3233/atde230607.
- [17] G. Xu, G. Jia, L. Shi, and Z. Zhang, "Personalized Course Recommendation System Fusing with Knowledge Graph and Collaborative Filtering," *Comput Intell Neurosci*, vol. 2021, 2021, doi: 10.1155/2021/9590502.
- [18] D. Liu, "Research on Personalized Resource Recommendation Based on User Profile and Collaborative Filtering Algorithm," *Adv Appl Sociol*, 2023, doi: 10.4236/aasoci.2023.1311048.
- [19] Y. Xu and T. Chen, "The Design of Personalized Learning Resource Recommendation System for Ideological and Political Courses," *International Journal of Reliability Quality and Safety Engineering*, 2023, doi: 10.1142/s0218539322500206.
- [20] W. Xu and Y. Zhou, "Course video recommendation with multimodal information in online learning platforms: A deep learning framework," *British Journal of Educational Technology*, vol. 51, no. 5, pp. 1734–1747, Sep. 2020, doi: 10.1111/bjet.12951.
- [21] D. L. Taylor, M. Yeung, and A. Z. Bashet, "Personalized and Adaptive Learning," 2021, doi: 10.1007/978-3-030-58948-6_2.
- [22] M. Chen, X. Wei, X. Zhang, and L. Ye, "Affection-Enhanced Personalized Question Recommendation in Online Learning," *Ksii Transactions on Internet and Information Systems*, 2023, doi: 10.3837/tiis.2023.12.003.
- [23] J. S. Alqahtani *et al.*, "Perspectives, practices, and challenges of online teaching during COVID-19 pandemic: A multinational survey," *Heliyon*, vol. 9, no. 8, Aug. 2023, doi: 10.1016/j.heliyon.2023.e19102.
- [24] A. Khalid, K. Lundqvist, and A. Yates, "A literature review of implemented recommendation techniques used in Massive Open online Courses," Jan. 01, 2022, Elsevier Ltd. doi: 10.1016/j.eswa.2021.115926.
- [25] X. Wei, S. Sun, D. Wu, and L. Zhou, "Personalized Online Learning Resource Recommendation Based on Artificial Intelligence and Educational Psychology," *Front Psychol*, vol. 12, Dec. 2021, doi: 10.3389/fpsyg.2021.767837.
- [26] Y. Fan, J. Zhang, D. Zu, and H. Zhan, "An Automatic Optimal Course Recommendation Method for Online Math Education Platforms Based on Bayesian Model," *International Journal of Emerging Technologies in Learning*, vol. 16, no. 13, pp. 95–107, 2021, doi: 10.3991/ijet.v16i13.24039.
- [27] Y. Wang, "Research on Online Learner Modeling and Course Recommendation Based on Emotional Factors," *Sci Program*, vol. 2022, 2022, doi: 10.1155/2022/5164186.
- [28] M. Gao, Y. Luo, and X. Hu, "Online Course Recommendation Using Deep Convolutional Neural Network with Negative Sequence Mining," *Wirel Commun Mob Comput*, vol. 2022, 2022, doi: 10.1155/2022/9054149.
- [29] B. Vesin, K. Mangaroska, K. Akhuseyinoglu, and M. Giannakos, "Adaptive Assessment and Content Recommendation in Online Programming Courses: On the Use of Elo-rating," *ACM Transactions on Computing Education*, vol. 22, no. 3, Jun. 2022, doi: 10.1145/3511886.
- [30] G. Xu, G. Jia, L. Shi, and Z. Zhang, "Personalized Course Recommendation System Fusing with Knowledge Graph and Collaborative Filtering," *Comput Intell Neurosci*, vol. 2021, 2021, doi: 10.1155/2021/9590502.
- [31] Q. Zhu, "Network Course Recommendation System Based on Double-Layer Attention Mechanism," *Sci Program*, vol. 2021, 2021, doi: 10.1155/2021/7613511.
- [32] A. Zhen and X. Wang, "The deep learning-based physical education course recommendation system under the internet of things," *Heliyon*, vol. 10, no. 19, Oct. 2024, doi: 10.1016/j.heliyon.2024.e38907.
- [33] C. Lilan and J. Zhong, "Intelligent recommendation system for College English courses based on graph convolutional networks," *Heliyon*, vol. 10, no. 8, Apr. 2024, doi: 10.1016/j.heliyon.2024.e29052.
- [34] F. Qu, M. Jiang, and Y. Qu, "An intelligent recommendation strategy for integrated online courses in vocational education based on short-term preferences," *Intelligent Systems with Applications*, vol. 22, Jun. 2024, doi: 10.1016/j.iswa.2024.200374.
- [35] S. Amin, M. I. Uddin, A. A. Alarood, W. K. Mashwani, A. O. Alzahrani, and H. A. Alzahrani, "An adaptable and personalized

- framework for top-N course recommendations in online learning,” *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-56497-1.
- [36] T. She and C. Chen, “Design of online and offline teaching system for piano improvisation accompaniment course for preschool education majors integrating meta-learning recommendation algorithm and CDIO,” *Applied Mathematics and Nonlinear Sciences*, vol. 9, no. 1, Jan. 2024, doi: 10.2478/amns-2024-1572.
- [37] J. W. Tzeng, N. F. Huang, A. C. Chuang, T. W. Huang, and H. Y. Chang, “Massive open online course recommendation system based on a reinforcement learning algorithm,” *Neural Comput Appl*, Jun. 2023, doi: 10.1007/s00521-023-08686-8.
- [38] J. Zhou, G. Jiang, W. Du, and C. Han, “Profiling temporal learning interests with time-aware transformers and knowledge graph for online course recommendation,” *Electronic Commerce Research*, vol. 23, no. 4, pp. 2357–2377, Dec. 2023, doi: 10.1007/s10660-022-09541-z.
- [39] L. Jia, “Online Course Learning Resource Recommendation Based on Difficulty Matching,” *International Journal of Emerging Technologies in Learning*, vol. 17, no. 22, pp. 156–169, 2022, doi: 10.3991/ijet.v17i22.35123.
- [40] M. C. Urdaneta-ponte, A. Méndez-zorrilla, and I. Oleagordia-ruiz, “Lifelong learning courses recommendation system to improve professional skills using ontology and machine learning,” *Applied Sciences (Switzerland)*, vol. 11, no. 9, May 2021, doi: 10.3390/app11093839.
- [41] Y. Fan, J. Zhang, D. Zu, and H. Zhan, “An Automatic Optimal Course Recommendation Method for Online Math Education Platforms Based on Bayesian Model,” *International Journal of Emerging Technologies in Learning*, vol. 16, no. 13, pp. 95–107, 2021, doi: 10.3991/ijet.v16i13.24039.
- [42] G. M. Dhananjaya, R. H. Goudar, A. A. Kulkarni, V. N. Rathod, and G. S. Hukkeri, “A Digital Recommendation System for Personalized Learning to Enhance Online Education: A Review,” *IEEE Access*, vol. 12, pp. 34019–34041, 2024, doi: 10.1109/ACCESS.2024.3369901.