

# REKOMENDASI JALUR BELAJAR BERBASIS PENCARIAN SEMANTIK PADA PLATFORM KURSUS DIGITAL

Vito Andareas Manik<sup>1\*</sup>

<sup>1</sup>Politeknik Negeri Samarinda; Jl. Cipto Mangunkusumo, Samarinda, Kalimantan Timur, Indonesia

## Keywords:

jalur belajar;  
pencarian semantik;  
sistem rekomendasi;  
embedding vektor;  
Technology Acceptance Model.

## Correspondent Email:

vitoandareas15@gmail.com

**Abstrak.** Platform kursus digital masih menghadapi tingkat penyelesaian belajar yang rendah karena pengguna sering kesulitan menentukan urutan materi sesuai tujuan, minat, dan kemampuan awal. Penelitian ini mengimplementasikan rekomendasi jalur belajar berbasis semantic search menggunakan model text-embedding-3-small pada platform kursus digital Genii. Setiap kursus direpresentasikan melalui judul, deskripsi, topik, tingkat kesulitan, dan ringkasan lesson, kemudian dikonversi menjadi embedding berdimensi 1536 dan diindeks pada layanan vector search. Rekomendasi dibentuk dari embedding preferensi pengguna, perhitungan cosine similarity, dan pengambilan Top-K kursus dengan skor tertinggi. Evaluasi penerimaan pengguna dilakukan menggunakan Technology Acceptance Model terhadap 50 responden dari 14 provinsi. Hasil menunjukkan nilai rata-rata Perceived Usefulness 4,40, Perceived Ease of Use 4,33, dan Behavioral Intention 4,38 pada skala 1-5, dengan reliabilitas konstruk Cronbach's alpha lebih besar dari 0,70. Korelasi Pearson menunjukkan hubungan positif signifikan antara Perceived Usefulness dan Behavioral Intention ( $r = 0,7324$ ,  $p < 0,001$ ) serta Perceived Ease of Use dan Behavioral Intention ( $r = 0,6847$ ,  $p < 0,001$ ). Temuan ini menunjukkan bahwa pendekatan embedding dapat diterapkan secara realistis pada platform pendidikan digital dan dipersepsikan bermanfaat serta mudah digunakan.

**Abstract.** Digital course platforms still face low learning completion because users often struggle to choose learning materials that match their goals, interests, and prior abilities. This study implements a learning path recommendation feature based on semantic search using the text-embedding-3-small model on a web-based platform named Genii. Each course is represented by its title, description, topic, difficulty level, and lesson summaries, then transformed into a 1536-dimensional embedding and indexed in a vector search service. Recommendations are generated by embedding user preferences, calculating cosine similarity, and retrieving Top-K highest-ranked courses. User acceptance was evaluated using the Technology Acceptance Model with 50 respondents from 14 provinces. Results show mean scores of 4.40 for Perceived Usefulness, 4.33 for Perceived Ease of Use, and 4.38 for Behavioral Intention on a 1-5 scale, with construct reliability above 0.70. Pearson correlation indicates significant positive relationships between Perceived Usefulness and Behavioral Intention ( $r = 0.7324$ ,  $p < 0.001$ ) and between Perceived Ease of Use and Behavioral Intention ( $r = 0.6847$ ,  $p < 0.001$ ). The findings indicate that embedding-based semantic search can be realistically implemented in digital education platforms and is perceived as useful and easy to use.



Copyright © 2026 The Author(s),  
Published by Jurnal Informatika dan  
Teknik Elektro Terapan. This is an  
open-access article distributed under  
the terms of the Creative Commons  
Attribution-NonCommercial 4.0  
International License (CC BY-NC  
4.0).

## 1. PENDAHULUAN

Pembelajaran daring telah menjadi bagian penting dari ekosistem pendidikan digital, tetapi tingkat penyelesaian belajar pada berbagai platform kursus masih menjadi persoalan. Banyak pengguna memiliki motivasi awal yang tinggi, namun tidak selalu memiliki kemampuan untuk memetakan urutan materi yang harus dipelajari. Kondisi ini terlihat pada studi terkait MOOC yang menunjukkan bahwa partisipasi tidak selalu berbanding lurus dengan penyelesaian kursus [10]. *Completion rate* juga dapat dipahami dari berbagai sudut pandang pengukuran, sehingga rendahnya penyelesaian tidak dapat dijelaskan hanya melalui satu faktor [5]. Pengalaman belajar pengguna dipengaruhi oleh struktur kursus, keterlibatan, dan desain aktivitas belajar yang dibangun selama proses pembelajaran [9]. Dengan demikian, penyediaan katalog materi yang banyak belum cukup; pengguna membutuhkan arahan belajar yang lebih terstruktur, personal, dan mudah dipahami.

Kebutuhan terhadap arahan belajar menjadi semakin relevan ketika pengguna baru memasuki platform. Pada tahap awal, pengguna sering belum memiliki riwayat klik, penyelesaian kursus, nilai kuis, atau pola interaksi yang dapat dipakai untuk membentuk rekomendasi berbasis perilaku. Kondisi tersebut dikenal sebagai *cold-start problem*, yaitu kondisi ketika sistem belum memiliki data historis yang cukup untuk menghasilkan rekomendasi personal [21]. Pada sistem pembelajaran adaptif, keterbatasan informasi awal dapat menghambat kemampuan sistem dalam menyesuaikan materi dengan kesiapan belajar pengguna [17]. Jika sistem tetap menunggu data historis, pengguna baru berpotensi menerima daftar materi yang terlalu umum dan akhirnya kesulitan memulai proses belajar.

Personalisasi jalur belajar dapat menjadi pendekatan untuk mengatasi persoalan tersebut. Jalur belajar tidak hanya menampilkan kursus secara terpisah, tetapi menyusun urutan materi yang relevan dengan tujuan, minat, dan level pengguna. Dalam konteks platform kursus digital, rekomendasi jalur belajar idealnya mampu menjawab pertanyaan praktis pengguna seperti materi apa yang harus dipelajari terlebih

dahulu, mengapa materi tersebut relevan, dan bagaimana materi berikutnya mendukung target belajar. Karena itu, kualitas rekomendasi tidak hanya ditentukan oleh skor algoritmik, tetapi juga oleh keterbacaan alasan rekomendasi dan kesesuaian hasil dengan profil yang dinyatakan pengguna.

Berdasarkan latar belakang tersebut, terdapat kesenjangan penelitian yang perlu diisi. Studi rekomendasi pendidikan umumnya membahas *recommender systems* secara konseptual, model akademis, atau evaluasi algoritmik, tetapi belum banyak yang memaparkan implementasi *end-to-end semantic search* berbasis embedding komersial pada platform kursus digital berbasis web dan mengevaluasi penerimaannya oleh pengguna. Penelitian ini mengisi kesenjangan tersebut dengan mengimplementasikan fitur rekomendasi pada platform Genii dan mengevaluasinya menggunakan Technology Acceptance Model (TAM). TAM digunakan karena mampu menjelaskan penerimaan teknologi melalui Perceived Usefulness, Perceived Ease of Use, dan Behavioral Intention [7], serta tetap relevan pada konteks e-learning [1], [11], [14], [19].

Kontribusi penelitian ini mencakup tiga aspek. Pertama, penelitian ini menyusun *pipeline* rekomendasi jalur belajar berbasis semantic search mulai dari onboarding, pembentukan embedding preferensi, pencarian Top-K pada indeks vektor, hingga penyajian reasoning pada halaman Journey. Kedua, penelitian ini merancang representasi kursus yang menggabungkan judul, deskripsi, topik, tingkat kesulitan, dan ringkasan lesson agar konteks semantik kursus lebih kaya dibandingkan representasi berbasis judul saja. Ketiga, penelitian ini mengevaluasi penerimaan pengguna terhadap fitur rekomendasi melalui 50 responden dari 14 provinsi dan menggabungkan analisis kuantitatif TAM dengan umpan balik kualitatif.

## 2. TINJAUAN PUSTAKA

### 2.1. Pencarian Semantik Berbasis Vector Embeddings

Salah satu pendekatan yang sesuai untuk situasi cold-start adalah *semantic search* berbasis *vector embeddings*. Berbeda dari

pencarian berbasis kata kunci yang mengandalkan kesamaan istilah, semantic search merepresentasikan teks ke dalam ruang vektor sehingga kemiripan dihitung berdasarkan kedekatan makna. Perkembangan representasi semantik modern dimulai dari model berbasis konteks seperti BERT [8], kemudian berkembang ke Sentence-BERT yang mengoptimalkan representasi kalimat untuk perhitungan similarity secara efisien [18]. Prinsip tersebut kini dapat diintegrasikan ke aplikasi melalui model embedding komersial, termasuk text-embedding-3-small yang menghasilkan embedding berdimensi 1536 [16]. Dalam implementasi aplikasi web, embedding dapat disimpan dalam indeks pencarian vektor agar sistem dapat menemukan materi yang paling dekat secara semantik dengan preferensi pengguna [6].

## 2.2. Rekomendasi Konten Pendidikan

Dalam domain pendidikan, pendekatan berbasis similarity memiliki dasar yang kuat karena konten belajar sering memiliki variasi istilah. Pengguna dapat menyatakan minat dengan frasa "belajar membuat website", sedangkan kursus yang relevan dapat berjudul "dasar HTML dan CSS" atau "front-end untuk pemula". Kecocokan tersebut sulit ditangkap jika hanya mengandalkan kata yang sama, tetapi dapat direpresentasikan melalui kedekatan makna. Penelitian mengenai *personalized educational content recommendation* menunjukkan bahwa cosine similarity dan sinyal kontekstual dapat mendukung personalisasi rekomendasi konten belajar [20]. Pendekatan berbasis konten juga telah lama dikenal dalam literatur recommender systems [12], dan dapat dikembangkan menjadi model hybrid yang menggabungkan beberapa sumber sinyal [4]. Di Indonesia, pendekatan berbasis kemiripan telah diterapkan pada berbagai domain, misalnya collaborative filtering dengan algoritma cosine similarity dan Jaccard similarity untuk rekomendasi produk e-commerce [23], serta sistem berbasis aturan dengan inferensi forward chaining untuk merekomendasikan buku bacaan berdasarkan minat pembaca [24]. Namun, kedua pendekatan tersebut bergantung pada riwayat interaksi pengguna atau aturan yang disusun secara manual, sehingga kurang sesuai untuk kondisi cold-start dan katalog konten yang terus

berubah; kesenjangan inilah yang diisi oleh pendekatan semantic search berbasis embedding pada penelitian ini.

## 2.3. Transparansi dan Technology Acceptance Model

Selain relevansi hasil, transparansi sistem juga penting. *Educational recommender systems* perlu menyajikan alasan rekomendasi agar pengguna memahami dasar pemilihan materi [2]. Transparansi membantu pengguna menilai apakah rekomendasi sesuai dengan kebutuhan, terutama ketika sistem menggunakan teknik yang tidak terlihat secara langsung oleh pengguna. Penelitian tentang *multi-stakeholder educational recommendations* juga menunjukkan bahwa penjelasan memengaruhi cara pengguna menerima hasil rekomendasi [22]. Penyajian rekomendasi secara visual dan interaktif dapat memperkuat pengalaman pengguna [13]. Penerimaan pengguna terhadap teknologi dapat dijelaskan melalui TAM yang mengukur Perceived Usefulness (PU), Perceived Ease of Use (PEOU), dan Behavioral Intention (BI) [7].

## 3. METODE PENELITIAN

### 3.1. Desain Penelitian

Penelitian ini menggunakan desain penelitian dan pengembangan (Research and Development/R&D). Tahap pengembangan menghasilkan artefak berupa platform kursus digital bernama Genii yang dilengkapi fitur rekomendasi jalur belajar. Tahap evaluasi mengukur penerimaan pengguna terhadap artefak tersebut menggunakan pendekatan kuantitatif berbasis TAM dan dilengkapi analisis kualitatif atas jawaban terbuka. Dengan desain ini, penelitian tidak hanya memeriksa apakah fitur dapat dibangun, tetapi juga apakah fitur tersebut dipersepsikan bermanfaat, mudah digunakan, dan mendorong niat penggunaan berkelanjutan.

Alur penelitian disusun secara sekuensial. Tahap pertama adalah identifikasi kebutuhan sistem dan penentuan komponen rekomendasi. Tahap kedua adalah pengembangan fitur menggunakan sprint Agile Scrum. Tahap ketiga adalah integrasi fitur ke antarmuka Journey. Tahap keempat adalah beta testing untuk menemukan masalah fungsional dan usability. Tahap kelima adalah evaluasi summative kepada responden yang menggunakan platform

selama periode uji. Ruang lingkup kebutuhan sistem dirangkum pada Tabel 1.

**Tabel 1. Ruang lingkup kebutuhan sistem**

| Aspek                 | Kebutuhan                                                                                  | Implikasi Desain                                                                      |
|-----------------------|--------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------|
| Profil pengguna       | Tujuan belajar, minat topik, dan preferensi tingkat kesulitan dikumpulkan saat onboarding. | Form preferensi yang ringkas dan mudah dipahami.                                      |
| Representasi konten   | Kursus memiliki metadata yang cukup untuk merepresentasikan makna materi.                  | Judul, deskripsi, topik, level, dan ringkasan lesson digabung sebagai teks embedding. |
| Pencarian rekomendasi | Rekomendasi dihasilkan walau riwayat interaksi belum tersedia.                             | Kueri preferensi dikonversi menjadi embedding dan dicocokkan dengan indeks vektor.    |
| Penyajian hasil       | Pengguna memahami alasan sebuah kursus direkomendasikan.                                   | Halaman Journey menampilkan Top-K kursus beserta reasoning singkat.                   |
| Evaluasi penerimaan   | Keberhasilan fitur diukur dari persepsi pengguna.                                          | Evaluasi menggunakan konstruk PU, PEOU, dan BI pada TAM.                              |

### 3.2. Pengembangan Sistem

Platform Genii dikembangkan menggunakan Next.js sebagai front-end framework, Convex sebagai backend-as-a-service sekaligus penyedia layanan vector search, dan model text-embedding-3-small untuk pembentukan representasi vektor. Pemilihan model embedding didasarkan pada kebutuhan untuk menghasilkan representasi teks yang cukup ringkas, dapat dipanggil melalui API, dan kompatibel dengan pencarian vektor di aplikasi web. Convex digunakan untuk menyimpan data aplikasi, mengelola fungsi backend, dan menyediakan indeks vector search yang dapat dipanggil dari alur rekomendasi [6].

Pengembangan sistem dilakukan dalam lima sprint. Sprint pertama membangun CRUD konten dan hierarki Course-Chapter-Lesson-Quiz. Sprint kedua berfokus pada autentikasi, otorisasi, dan pengelolaan peran pengguna. Sprint ketiga mengintegrasikan embedding dengan Convex Vector Search. Sprint keempat mengimplementasikan rekomendasi end-to-end dari onboarding hingga Top-K. Sprint kelima menyatukan front-end dan back-end ke dalam alur aplikasi yang utuh, termasuk landing page, katalog kursus, detail kursus, lesson, quiz,

dashboard progres, administrasi konten, dan halaman Journey.

### 3.3. Struktur Data dan Representasi Kursus

Konten pembelajaran pada Genii disusun dalam hierarki Course-Chapter-Lesson-Quiz. Hierarki ini memungkinkan sistem menyimpan informasi kursus secara terstruktur, tetapi rekomendasi membutuhkan representasi ringkas yang dapat dibandingkan dengan preferensi pengguna. Karena itu, setiap kursus direpresentasikan sebagai teks gabungan yang memuat lima atribut sebagaimana dirangkum pada Tabel 2. Strategi ini dimaksudkan agar embedding tidak hanya menangkap label umum kursus, tetapi juga substansi materi yang dipelajari.

**Tabel 2. Atribut representasi kursus untuk embedding**

| Atribut           | Deskripsi                                                 | Contoh                                         |
|-------------------|-----------------------------------------------------------|------------------------------------------------|
| Judul             | Nama kursus yang merangkum topik utama.                   | Dasar-Dasar Python                             |
| Deskripsi         | Ringkasan tujuan dan cakupan kursus.                      | Mengenal sintaks, tipe data, dan kontrol alur. |
| Topik             | Tag atau tema utama untuk pengelompokan konten.           | python, programming, dasar                     |
| Tingkat kesulitan | Indikasi level pembelajaran pengguna.                     | pemula                                         |
| Ringkasan lesson  | Intisari materi lesson untuk memperkaya konteks semantik. | variabel, fungsi, loop, list                   |

Teks representasi dibentuk dengan menggabungkan atribut tersebut ke dalam format naratif singkat. Contoh representasi dapat berupa: "Kursus Dasar-Dasar Python untuk pemula membahas sintaks, tipe data, kontrol alur, variabel, fungsi, loop, dan list." Representasi tersebut kemudian dikonversi menjadi embedding berdimensi 1536 oleh model text-embedding-3-small [16]. Embedding kursus disimpan dalam indeks vector search dan diperbarui kembali ketika konten kursus dibuat, diubah, atau dihapus agar konsistensi antara data kursus dan indeks pencarian tetap terjaga.

Pendekatan representasi multi-atribut dipilih karena judul kursus saja sering tidak cukup untuk menggambarkan ruang lingkup materi. Dua kursus dapat memiliki judul yang mirip, tetapi membahas tingkat kesulitan dan detail


lesson yang berbeda. Sebaliknya, dua kursus dengan judul berbeda dapat memiliki kedekatan makna karena mencakup keterampilan yang sama. Dengan memasukkan ringkasan lesson, sistem memperoleh sinyal tambahan yang membantu pencarian semantik membedakan materi dasar, lanjutan, dan materi prasyarat.

### 3.4. Arsitektur Rekomendasi

Arsitektur rekomendasi diawali dari proses onboarding yang meminta pengguna menyatakan tujuan belajar, minat topik, dan preferensi tingkat kesulitan. Preferensi tersebut dirangkai menjadi teks kueri, kemudian dikonversi menjadi embedding kueri menggunakan model yang sama dengan embedding kursus. Penggunaan model yang sama penting agar kueri dan kursus berada pada ruang vektor yang kompatibel. Setelah itu, sistem melakukan pencarian Top-K pada indeks vector search dan menghitung kedekatan semantik menggunakan cosine similarity. Alur lengkap pipeline rekomendasi ditunjukkan pada Gambar 1, sedangkan tahapan dan keluaran setiap proses dirangkum pada Tabel 3.

Kemiripan semantik antara kueri pengguna  $q$  dan representasi kursus  $c$  dihitung menggunakan Persamaan (1). Nilai similarity yang lebih tinggi menunjukkan kedekatan makna yang lebih besar. Berdasarkan skor tersebut, sistem mengambil Top-K kursus dengan skor tertinggi. Penyaringan tambahan dapat diterapkan berdasarkan tingkat kesulitan, prasyarat, atau kategori konten jika informasi tersebut tersedia. Alur ini dirancang agar rekomendasi dapat diberikan sejak awal penggunaan platform, sekalipun riwayat interaksi pengguna masih terbatas.

$$\cos(q, c) = (q \cdot c) / (||q|| ||c||) \quad (1)$$



**Gambar 1. Pipeline rekomendasi jalur belajar berbasis semantic search**


**Tabel 3. Tahapan rekomendasi dan keluaran sistem**

| Tahap | Input                             | Proses                                                              | Output                         |
|-------|-----------------------------------|---------------------------------------------------------------------|--------------------------------|
| 1     | Preferensi onboarding             | Menggabungkan tujuan, minat, dan level ke teks kueri.               | Teks preferensi pengguna       |
| 2     | Teks preferensi                   | Memanggil model embedding untuk membentuk vektor kueri.             | Embedding kueri                |
| 3     | Embedding kueri dan indeks kursus | Menghitung kedekatan dengan cosine similarity pada vector search.   | Daftar kandidat Top-K          |
| 4     | Kandidat Top-K                    | Menerapkan filter level atau prasyarat jika tersedia.               | Kandidat terpilih              |
| 5     | Kandidat terpilih                 | Menyusun urutan pada halaman Journey dan membuat reasoning singkat. | Jalur belajar yang ditampilkan |


### 3.5. Skenario Rekomendasi dan Penyajian Hasil

Secara operasional, fitur rekomendasi bekerja ketika pengguna menyelesaikan onboarding atau memperbarui preferensi. Jika pengguna memilih tujuan "belajar pemrograman dari awal", topik "Python", dan level "pemula", sistem membentuk embedding kueri yang menggambarkan kebutuhan tersebut. Hasil rekomendasi kemudian ditampilkan sebagai urutan belajar pada halaman Journey. Setiap item rekomendasi disertai alasan singkat, misalnya kecocokan topik Python, kesesuaian dengan level pemula, atau relevansi lesson dasar seperti variabel, kontrol alur, dan fungsi.

Penyajian reasoning menjadi bagian penting dari desain fitur karena pengguna perlu mengetahui mengapa sistem menyarankan kursus tertentu. Reasoning tidak dimaksudkan sebagai penjelasan teknis tentang embedding, tetapi sebagai penjelasan sederhana yang menghubungkan preferensi pengguna dengan karakteristik kursus. Dengan demikian, antarmuka menutupi kompleksitas teknis seperti API call, perhitungan similarity, dan pencarian vektor, tetapi tetap memberi sinyal transparansi yang dapat dibaca oleh pengguna. Ilustrasi tampilan halaman Journey ditunjukkan pada Gambar 2 dan Gambar 3.



**Gambar 2. Tampilan halaman Journey dan hasil rekomendasi**



**Gambar 3. Tampilan halaman Journey dan hasil rekomendasi**

### 3.6. Evaluasi Pengguna

Evaluasi dilakukan dalam dua tahap. Tahap formative berupa beta testing dengan 2 pengguna selama satu hingga dua minggu untuk memperoleh umpan balik awal terkait fungsionalitas, navigasi, dan keterbacaan rekomendasi. Setelah perbaikan minor, evaluasi summative dilakukan kepada 50 responden. Responden menggunakan platform selama satu hingga dua minggu sebelum mengisi kuesioner. Pengambilan sampel menggunakan purposive sampling dengan kriteria berusia minimal 18 tahun, memiliki akses internet, dan bersedia mencoba platform Genii selama periode evaluasi.

Instrumen evaluasi menggunakan User Acceptance Testing berbasis TAM dengan 12 item skala Likert 1-5. Konstruk Perceived Usefulness terdiri atas enam item yang menilai manfaat fitur rekomendasi terhadap efektivitas belajar. Konstruk Perceived Ease of Use terdiri atas tiga item yang menilai kemudahan interaksi dengan platform. Konstruk Behavioral Intention terdiri atas tiga item yang menilai kecenderungan penggunaan kembali dan rekomendasi kepada orang lain. Kuesioner juga memuat pertanyaan terbuka untuk menangkap

pengalaman pengguna secara kualitatif. Rancangan instrumen disajikan pada Tabel 4.

**Tabel 4. Rancangan instrumen Technology Acceptance Model**

| Konstruk | Jumlah Item | Fokus Pengukuran                                  | Contoh Pernyataan                                                          |
|----------|-------------|---------------------------------------------------|----------------------------------------------------------------------------|
| PU       | 6           | Manfaat rekomendasi terhadap efektivitas belajar. | Fitur rekomendasi membantu menemukan materi yang sesuai kebutuhan belajar. |
| PEOU     | 3           | Kemudahan memahami dan menggunakan fitur.         | Alur penggunaan rekomendasi mudah dipahami tanpa instruksi tambahan.       |
| BI       | 3           | Niat penggunaan berkelanjutan.                    | Saya berniat menggunakan kembali fitur ini.                                |

### 3.7. Teknik Analisis Data

Data kuantitatif dianalisis menggunakan statistik deskriptif berupa mean dan standar deviasi. Reliabilitas konstruk diuji menggunakan Cronbach's alpha, sedangkan validitas item diperiksa menggunakan item-total correlation. Ambang reliabilitas 0,70 digunakan sebagai acuan umum bahwa konstruk memiliki konsistensi internal yang memadai [15]. Hubungan antar konstruk dianalisis dengan korelasi Pearson untuk mengukur kekuatan asosiasi antara PU, PEOU, dan BI.

Korelasi Pearson dalam penelitian ini digunakan sebagai ukuran asosiasi, bukan dasar untuk menyatakan kausalitas. Dengan kata lain, nilai korelasi yang tinggi menunjukkan bahwa persepsi manfaat atau kemudahan berkaitan erat dengan niat penggunaan, tetapi tidak membuktikan bahwa salah satu konstruk secara langsung menyebabkan konstruk lain. Untuk menguji hubungan kausal, penelitian lanjutan dapat menggunakan Structural Equation Modeling atau desain eksperimen terkontrol.

Data kualitatif dari jawaban terbuka dianalisis secara tematik mengikuti prosedur Braun dan Clarke [3]. Tahap analisis mencakup familiarisasi terhadap jawaban responden, pembentukan kode awal, pengelompokan kode ke tema, peninjauan tema, penamaan tema, dan penyusunan interpretasi. Analisis kualitatif digunakan untuk melengkapi hasil kuantitatif, terutama untuk menjelaskan aspek antarmuka, reasoning, serta saran pengembangan yang tidak seluruhnya tertangkap oleh skor Likert.

### 3.8. Pengendalian Mutu Data

Pengendalian mutu data dilakukan untuk memastikan bahwa teks representasi kursus benar-benar mencerminkan isi pembelajaran. Setiap kursus perlu memiliki judul yang spesifik, deskripsi yang menjelaskan tujuan belajar, topik yang konsisten, tingkat kesulitan yang jelas, dan ringkasan lesson yang merepresentasikan konsep utama. Tanpa kualitas metadata yang memadai, embedding dapat membawa sinyal yang kurang akurat sehingga hasil similarity menjadi lebih sulit diinterpretasikan.

Sistem juga perlu memiliki strategi fallback ketika metadata belum lengkap atau embedding gagal dibentuk. Pada kondisi tersebut, kursus dapat dikeluarkan sementara dari indeks rekomendasi atau ditandai untuk diperbarui oleh administrator. Pengendalian ini menjaga agar halaman Journey tidak menampilkan rekomendasi yang lemah hanya karena data kursus belum siap. Dengan demikian, kualitas rekomendasi tidak hanya bergantung pada model embedding, tetapi juga pada tata kelola konten yang digunakan sebagai masukan sistem.

## 4. HASIL DAN PEMBAHASAN

### 4.1. Implementasi Fitur Rekomendasi

Implementasi menghasilkan platform Genii yang fungsional dan terintegrasi. Halaman utama terdiri atas landing page, autentikasi multi-metode, onboarding preferensi, dashboard progres, halaman Journey untuk rekomendasi jalur belajar, katalog kursus, detail kursus, lesson, quiz, dan halaman administrasi. Halaman Journey menjadi pusat implementasi fitur rekomendasi karena sistem menampilkan kursus hasil similarity search sebagai urutan belajar yang disarankan. Setiap rekomendasi tidak hanya menampilkan nama kursus, tetapi juga reasoning singkat yang menjelaskan kecocokan dengan topik, level, atau tujuan belajar pengguna.

Dari sisi teknis, sistem mampu membentuk embedding kueri dan melakukan pencarian similarity secara real-time. Sebagai ilustrasi karakteristik output, kueri preferensi dengan topik "pemrograman Python untuk pemula" menghasilkan kursus relevan dengan skor cosine similarity pada kisaran 0,78-0,92, sedangkan kursus yang tidak berkaitan menghasilkan skor di bawah 0,50. Pola ini

menunjukkan bahwa model embedding dapat membedakan konten relevan dan tidak relevan secara semantik. Integrasi layanan embedding dan vector search memungkinkan seluruh pipeline dari pembentukan kueri hingga pengambilan Top-K berjalan tanpa intervensi manual dari pengguna.

Hasil implementasi juga menunjukkan bahwa representasi kursus multi-atribut berperan penting. Ketika ringkasan lesson disertakan, sistem tidak hanya mengandalkan judul kursus, tetapi juga konteks materi yang dipelajari. Ini membantu sistem membedakan kursus pemula yang membahas konsep dasar dari kursus lanjutan yang memiliki topik umum sama. Dalam konteks pembelajaran, perbedaan level tersebut penting karena rekomendasi yang terlalu sulit dapat menurunkan motivasi, sedangkan rekomendasi yang terlalu mudah dapat mengurangi persepsi manfaat. Contoh skenario uji fungsional disajikan pada Tabel 5.

**Tabel 5. Contoh skenario uji fungsional rekomendasi**

| Skenario | Preferensi Pengguna                       | Ekspektasi Keluaran                                     |
|----------|-------------------------------------------|---------------------------------------------------------|
| S1       | Python dasar, level pemula.               | Kursus Python dasar dengan reasoning level pemula.      |
| S2       | Pengembangan web/front-end, level pemula. | Kursus HTML, CSS, atau front-end pemula diprioritaskan. |
| S3       | Topik lanjutan, level menengah.           | Kursus lanjutan atau prasyarat relevan diprioritaskan.  |

### 4.2. Profil Responden

Evaluasi summative melibatkan 50 responden dari 14 provinsi. Karakteristik demografis responden disajikan pada Tabel 6. Mayoritas responden berjenis kelamin perempuan sebesar 74%, sedangkan laki-laki sebesar 26%. Dari sisi usia, 64% responden berada pada rentang 18-24 tahun dan 36% berada pada rentang 25-30 tahun. Berdasarkan status ekonomi sosial, responden didominasi kelompok middle sebesar 62%, disusul lower sebesar 20% dan upper sebesar 18%.

Komposisi tersebut menunjukkan bahwa sampel penelitian didominasi oleh pengguna muda yang relatif akrab dengan teknologi digital. Kondisi ini sesuai dengan konteks awal platform kursus digital, tetapi tetap perlu diperhatikan dalam interpretasi generalisasi. Cakupan geografis dari 14 provinsi

memberikan variasi latar pengguna yang cukup untuk studi awal, namun penelitian lanjutan tetap perlu melibatkan distribusi usia, jenis kelamin, dan latar pendidikan yang lebih seimbang.

**Tabel 6. Ringkasan demografi responden**

| Kategori              | Deskripsi   | Frekuensi | Persentase |
|-----------------------|-------------|-----------|------------|
| Jenis kelamin         | Laki-laki   | 13        | 26%        |
| Jenis kelamin         | Perempuan   | 37        | 74%        |
| Usia                  | 18-24 tahun | 32        | 64%        |
| Usia                  | 25-30 tahun | 18        | 36%        |
| Status ekonomi sosial | Upper       | 9         | 18%        |
| Status ekonomi sosial | Middle      | 31        | 62%        |
| Status ekonomi sosial | Lower       | 10        | 20%        |
| Cakupan geografis     | 14 provinsi | -         | -          |

#### 4.3. Reliabilitas dan Validitas Instrumen

Sebelum persepsi pengguna diinterpretasikan, instrumen evaluasi diuji reliabilitas dan validitasnya. Hasil uji Cronbach's alpha menunjukkan bahwa seluruh konstruk TAM memiliki nilai lebih besar dari 0,70. Konstruk PU memperoleh alpha 0,8412, PEOU memperoleh alpha 0,7371, dan BI memperoleh alpha 0,7699. Nilai tersebut menunjukkan bahwa item pada setiap konstruk memiliki konsistensi internal yang baik atau dapat diterima, sebagaimana dirangkum pada Tabel 7.

**Tabel 7. Reliabilitas konstruk TAM**

| Konstruk | Jumlah Item | Cronbach's Alpha | Interpretasi   |
|----------|-------------|------------------|----------------|
| PU       | 6           | 0,8412           | Baik           |
| PEOU     | 3           | 0,7371           | Dapat diterima |
| BI       | 3           | 0,7699           | Dapat diterima |

Analisis item-total correlation memperlihatkan bahwa seluruh item signifikan pada level  $p < 0,001$ . Item yang paling representatif untuk masing-masing konstruk adalah PU4 dengan  $r = 0,7494$ , PEOU3 dengan  $r = 0,6074$ , dan BI1 dengan  $r = 0,7356$ , sebagaimana disajikan pada Tabel 8. Temuan ini menunjukkan bahwa item-item tersebut paling kuat merefleksikan konstruk yang diukur dan memperkuat keyakinan bahwa instrumen

dapat digunakan untuk membaca penerimaan pengguna terhadap fitur rekomendasi.

**Tabel 8. Item paling representatif berdasarkan item-total correlation**


| Konstruk | Item  | Nilai r | Makna                                                   |
|----------|-------|---------|---------------------------------------------------------|
| PU       | PU4   | 0,7494  | Item paling kuat merefleksikan persepsi manfaat fitur.  |
| PEOU     | PEOU3 | 0,6074  | Item paling kuat merefleksikan kemudahan penggunaan.    |
| BI       | BI1   | 0,7356  | Item paling kuat merefleksikan niat penggunaan kembali. |

#### 4.4. Hasil Analisis Deskriptif

Seluruh konstruk TAM memperoleh skor rata-rata lebih besar dari 4,30 pada skala 1-5. Nilai rata-rata PU sebesar 4,40 menunjukkan bahwa fitur rekomendasi dipersepsikan bermanfaat untuk membantu pengguna menemukan materi belajar. Nilai rata-rata PEOU sebesar 4,33 menunjukkan bahwa pengguna menilai fitur mudah digunakan, sementara nilai rata-rata BI sebesar 4,38 menunjukkan kecenderungan penggunaan berkelanjutan. Ringkasan skor disajikan pada Tabel 9 dan divisualisasikan pada Gambar 3.

**Tabel 9. Rata-rata konstruk TAM**

| Konstruk | Rata-rata | Interpretasi   |
|----------|-----------|----------------|
| PU       | 4,40      | Sangat positif |
| PEOU     | 4,33      | Sangat positif |
| BI       | 4,38      | Sangat positif |



**Gambar 3. Visualisasi rata-rata konstruk TAM**

Skor tertinggi pada dimensi PU terdapat pada item PU6 dengan mean 4,54 dan standar deviasi 0,58. Item tersebut mengukur persepsi bahwa penjelasan yang disesuaikan membuat pembelajaran lebih efektif. Hal ini mengindikasikan bahwa reasoning singkat pada hasil rekomendasi bukan sekadar elemen

tambahan, melainkan komponen yang dianggap berdampak oleh pengguna. Pada dimensi PEOU, seluruh item memperoleh skor tinggi dan merata pada kisaran 4,28-4,40. Pada dimensi BI, item BI1 yang mengukur niat menggunakan kembali memperoleh skor tertinggi dengan mean 4,42 dan standar deviasi 0,67.

Hasil deskriptif tersebut menunjukkan bahwa pengguna tidak hanya menilai sistem mudah dipakai, tetapi juga melihat manfaat langsung dari fitur rekomendasi. Dalam TAM, manfaat yang dirasakan sering menjadi faktor penting yang memengaruhi niat penggunaan, terutama ketika pengguna merasa fitur tersebut menghemat waktu, mengurangi kebingungan, atau membantu menentukan prioritas belajar. Pada konteks Genii, persepsi manfaat muncul karena sistem menghubungkan preferensi pengguna dengan materi yang secara semantik relevan dan menjelaskannya melalui reasoning yang mudah dipahami.

#### 4.5. Analisis Korelasi

Analisis korelasi Pearson digunakan untuk melihat kekuatan asosiasi antara konstruk TAM. Hasilnya menunjukkan bahwa PEOU dan BI memiliki korelasi positif signifikan dengan  $r = 0,6847$  dan  $p < 0,001$ , sedangkan PU dan BI memiliki korelasi positif signifikan dengan  $r = 0,7324$  dan  $p < 0,001$ , sebagaimana disajikan pada Tabel 10. Kedua nilai tersebut menunjukkan hubungan yang kuat, tetapi korelasi PU terhadap BI lebih tinggi dibandingkan korelasi PEOU terhadap BI.

**Tabel 10. Korelasi Pearson antar konstruk TAM**

| Relasi  | r      | p-value | Keterangan         |
|---------|--------|---------|--------------------|
| PEOU-BI | 0,6847 | < 0,001 | Positif signifikan |
| PU-BI   | 0,7324 | < 0,001 | Positif signifikan |

Nilai korelasi tersebut mengindikasikan bahwa niat pengguna untuk menggunakan fitur secara berkelanjutan lebih erat berkaitan dengan manfaat yang dirasakan daripada kemudahan penggunaan. Artinya, antarmuka yang mudah memang penting, tetapi pengguna cenderung lebih terdorong untuk kembali menggunakan fitur ketika rekomendasi benar-benar membantu menentukan materi belajar. Pola ini selaras dengan studi TAM pada konteks e-learning yang menunjukkan bahwa usefulness

merupakan faktor penting dalam adopsi layanan pembelajaran digital [1], [14], [19].

Temuan korelasi juga memberikan arahan praktis bagi pengembangan platform. Fokus pengembangan tidak cukup hanya pada penyederhanaan antarmuka, tetapi juga pada peningkatan kualitas relevansi, kejelasan reasoning, dan kesesuaian urutan jalur belajar. Dengan meningkatkan kualitas manfaat yang dirasakan, sistem berpotensi mempertahankan niat penggunaan berkelanjutan. Namun, karena desain penelitian bersifat korelasional, hubungan tersebut tetap harus dibaca sebagai asosiasi, bukan klaim sebab-akibat.

#### 4.6. Analisis Kualitatif Umpan Balik Responden

Selain data kuantitatif, penelitian ini menganalisis 50 jawaban terbuka dari responden. Analisis tematik menghasilkan empat tema utama, yaitu kemudahan penggunaan, kualitas penjelasan dan materi, saran pengembangan, serta personalisasi efektif. Sebanyak 56% responden memberikan sentimen positif, 24% memberikan sentimen netral dengan saran konstruktif, dan 20% memberikan kritik terhadap aspek tertentu. Distribusi tema ditampilkan pada Tabel 11.

**Tabel 11. Distribusi tema umpan balik kualitatif**

| Tema                           | Jumlah Responden | Persentase | Deskripsi                                                  |
|--------------------------------|------------------|------------|------------------------------------------------------------|
| Kemudahan penggunaan           | 18               | 36%        | Apresiasi terhadap UI/UX yang intuitif.                    |
| Kualitas penjelasan dan materi | 18               | 36%        | Penilaian positif terhadap kualitas konten dan penjelasan. |
| Saran pengembangan             | 18               | 36%        | Usulan ekspansi konten dan fitur.                          |
| Personalisasi efektif          | 4                | 8%         | Apresiasi spesifik terhadap kecocokan konten.              |

Tema kemudahan penggunaan tampak pada respons yang menyebut aplikasi mudah dipahami oleh pemula dan nyaman digunakan untuk pembelajaran. Respons ini sejalan dengan tingginya skor PEOU dan memperkuat interpretasi bahwa kompleksitas teknis semantic search berhasil disembunyikan dari pengguna. Pengguna tidak perlu memahami embedding atau vector search untuk memperoleh manfaat; mereka cukup mengisi

preferensi dan melihat rekomendasi yang dihasilkan sistem.

Tema kualitas penjelasan dan materi tampak pada apresiasi terhadap fitur AI yang interaktif serta rekomendasi pembelajaran dari tingkat awal. Respons seperti "Rekomendasi pembelajaran dan tutorial mulai dari beginning sangat membantu" menunjukkan bahwa pengguna menghargai struktur awal yang jelas. Tema personalisasi efektif muncul pada respons yang secara eksplisit menyebut personalisasi konten dan penggunaan AI sebagai aspek yang disukai. Meskipun proporsinya lebih kecil, tema ini penting karena secara langsung berkaitan dengan tujuan utama penelitian, yaitu menyediakan rekomendasi yang sesuai dengan kebutuhan pengguna.

Tema saran pengembangan menunjukkan bahwa pengguna mengharapkan cakupan materi yang lebih luas. Beberapa responden menyarankan agar Genii tidak hanya berfokus pada pemrograman, tetapi juga mendukung bidang lain seperti CAD. Saran ini tidak mengubah fokus penelitian, tetapi memberikan arah praktis bahwa pipeline semantic search dapat diperluas selama konten memiliki metadata dan ringkasan lesson yang cukup. Dengan demikian, temuan kualitatif memperkaya hasil kuantitatif sekaligus menunjukkan prioritas pengembangan fitur berikutnya.

#### 4.7. Pembahasan Temuan Utama

Secara keseluruhan, hasil penelitian menunjukkan bahwa semantic search berbasis text-embedding-3-small dapat diimplementasikan secara realistis pada platform kursus digital Genii dan diterima positif oleh pengguna. Tingginya skor PU dapat dijelaskan oleh kemampuan sistem mencocokkan preferensi pengguna dengan konten berdasarkan kedekatan makna. Pengguna tidak harus memasukkan kata yang sama dengan judul kursus, karena sistem membandingkan representasi vektor dari kebutuhan belajar dan konten kursus. Hal ini penting dalam pembelajaran digital karena pengguna pemula sering tidak mengetahui istilah teknis yang tepat untuk mencari materi.

Tingginya skor PEOU menunjukkan bahwa antarmuka berhasil mengabstraksikan kompleksitas teknis dari pengguna. Proses yang secara teknis melibatkan API call ke model

embedding, pembentukan vektor, komputasi cosine similarity, pencarian pada indeks vektor, dan penyusunan Top-K berlangsung di balik antarmuka yang sederhana. Bagi pengguna, proses tersebut tampil sebagai pengalaman yang familiar: mengisi preferensi, membuka halaman Journey, dan membaca daftar rekomendasi. Temuan ini sejalan dengan pandangan bahwa rekomendasi yang divisualisasikan secara interaktif dapat memperkuat pengalaman belajar [13].

Penyajian reasoning singkat pada hasil rekomendasi menjadi salah satu temuan penting. Skor PU6 yang tinggi menunjukkan bahwa pengguna menilai penjelasan yang disesuaikan dapat membuat pembelajaran lebih efektif. Ini mendukung gagasan bahwa transparansi bukan hanya aspek etis, tetapi juga aspek usability dalam recommender systems pendidikan [2], [22]. Ketika pengguna memahami alasan sebuah kursus direkomendasikan, mereka dapat menilai kesesuaian rekomendasi dan lebih percaya untuk mengikuti jalur belajar yang disarankan.

Dalam konteks cold-start, pendekatan yang digunakan penelitian ini layak karena rekomendasi dapat dihasilkan dari preferensi eksplisit pada onboarding. Sistem tidak harus menunggu histori klik, penyelesaian kursus, atau rating. Ini menjawab tantangan yang sering muncul pada sistem rekomendasi yang bergantung pada data historis [21]. Walaupun demikian, pendekatan semantic search bukan pengganti seluruh bentuk personalisasi. Setelah data interaksi terkumpul, rekomendasi dapat dikembangkan menjadi model hybrid yang menggabungkan embedding, perilaku pengguna, progres belajar, dan performa kuis [4], sebagaimana arah pengembangan yang juga disarankan pada studi collaborative filtering berbasis cosine similarity [23]. Ringkasan interpretasi hasil utama disajikan pada Tabel 12.

**Tabel 12. Ringkasan interpretasi hasil utama**

| Aspek                | Hasil Temuan                                                             | Interpretasi                                                                                 |
|----------------------|--------------------------------------------------------------------------|----------------------------------------------------------------------------------------------|
| Implementasi teknis  | Pipeline embedding, vector search, Top-K, dan Journey berhasil dibangun. | Semantic search dapat digunakan sebagai dasar rekomendasi awal pada platform kursus digital. |
| Perceived Usefulness | PU = 4,40 dan PU6 memiliki mean 4,54.                                    | Reasoning singkat dan kecocokan materi                                                       |

|                       |                                                                                        |                                                                                     |
|-----------------------|----------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|
|                       |                                                                                        | meningkatkan persepsi manfaat.                                                      |
| Perceived Ease of Use | PEOU = 4,33 dengan skor item relatif merata.                                           | Antarmuka mampu menyembunyikan kompleksitas teknis dari pengguna.                   |
| Behavioral Intention  | BI = 4,38 dan korelasi PU-BI lebih tinggi daripada PEOU-BI.                            | Manfaat yang dirasakan berasosiasi kuat dengan niat penggunaan berkelanjutan.       |
| Umpan balik terbuka   | Tema kemudahan penggunaan dan kualitas materi masing-masing muncul pada 36% responden. | Hasil kualitatif mendukung temuan kuantitatif dan memberi arah pengembangan konten. |

#### 4.8. Implikasi Praktis dan Keterbatasan

Dari sisi praktis, penelitian ini menunjukkan bahwa platform kursus digital dapat memulai personalisasi tanpa harus menunggu data historis pengguna. Onboarding yang dirancang dengan baik dapat menjadi sumber sinyal awal untuk membentuk kueri semantik. Bagi pengelola platform, implikasinya adalah kualitas metadata kursus dan ringkasan lesson menjadi faktor penting. Konten yang tidak memiliki deskripsi jelas akan lebih sulit direpresentasikan secara semantik, sehingga rekomendasi yang dihasilkan juga berpotensi kurang tepat.

Implikasi lainnya adalah pentingnya merancang reasoning yang ringkas, spesifik, dan mudah dipahami. Reasoning yang terlalu teknis dapat membingungkan pengguna, sedangkan reasoning yang terlalu umum tidak memberi nilai tambah. Dalam konteks Genii, reasoning sebaiknya menjelaskan relasi sederhana antara preferensi pengguna dan atribut kursus, misalnya kecocokan topik, kesesuaian level, atau relevansi lesson awal. Pendekatan ini membuat sistem terasa lebih transparan tanpa membebani pengguna dengan detail algoritmik.

Penelitian ini memiliki beberapa keterbatasan. Pertama, evaluasi berfokus pada penerimaan pengguna sehingga kualitas rekomendasi belum diukur secara objektif menggunakan metrik information retrieval seperti Precision@K, Recall@K, atau nDCG. Ketidadaan ground truth menjadikan klaim relevansi rekomendasi bersifat perseptual, bukan empiris. Kedua, sampel didominasi oleh perempuan dan kelompok usia 18-24 tahun,

sehingga generalisasi ke populasi yang lebih beragam perlu dilakukan dengan hati-hati. Ketiga, penelitian ini belum melakukan perbandingan langsung dengan baseline seperti keyword matching atau collaborative filtering, sehingga keunggulan komparatif semantic search belum dapat diklaim secara empiris.

Arah penelitian lanjutan dapat difokuskan pada tiga hal. Pertama, membangun dataset ground truth untuk mengevaluasi relevansi rekomendasi secara objektif. Kedua, membandingkan semantic search dengan baseline pencarian kata kunci dan model hybrid. Ketiga, mengukur dampak fitur rekomendasi terhadap completion rate, retensi pengguna, dan progres belajar dalam jangka menengah. Dengan agenda tersebut, penelitian berikutnya dapat memperkuat bukti bukan hanya pada tingkat penerimaan pengguna, tetapi juga pada dampak pembelajaran.

#### 5. KESIMPULAN

Penelitian ini berhasil mengimplementasikan fitur rekomendasi jalur belajar berbasis semantic search menggunakan model text-embedding-3-small secara end-to-end pada platform kursus digital Genii, mulai dari onboarding preferensi, pembentukan embedding, pencarian Top-K dengan cosine similarity pada indeks vector search, hingga penyajian reasoning pada halaman Journey. Representasi kursus yang menggabungkan judul, deskripsi, topik, tingkat kesulitan, dan ringkasan lesson terbukti menyediakan konteks semantik yang cukup kaya untuk menghasilkan rekomendasi yang relevan, dengan skor cosine similarity konten relevan pada kisaran 0,78-0,92 dan konten tidak berkaitan di bawah 0,50. Pendekatan ini juga menjawab persoalan cold-start karena rekomendasi dapat dihasilkan dari preferensi eksplisit pengguna tanpa menunggu data historis interaksi.

Evaluasi penerimaan pengguna terhadap 50 responden dari 14 provinsi menunjukkan persepsi yang sangat positif, dengan nilai rata-rata Perceived Usefulness 4,40, Perceived Ease of Use 4,33, dan Behavioral Intention 4,38 pada skala 1-5, serta reliabilitas konstruk Cronbach's alpha lebih besar dari 0,70. Analisis korelasi Pearson menunjukkan asosiasi positif yang signifikan antara PU dan BI ( $r = 0,7324$ ,  $p < 0,001$ ) serta PEOU dan BI ( $r = 0,6847$ ,  $p < 0,001$ ), sehingga manfaat yang dirasakan

berasosiasi lebih kuat dengan niat penggunaan berkelanjutan dibandingkan kemudahan penggunaan. Temuan kualitatif memperkuat hasil kuantitatif dengan menunjukkan bahwa kemudahan antarmuka, kualitas penjelasan, dan personalisasi konten menjadi aspek yang diapresiasi pengguna.

Meskipun demikian, penelitian ini masih terbatas pada evaluasi perseptual sehingga kualitas rekomendasi belum diukur secara objektif dan belum dibandingkan dengan baseline lain. Penelitian lanjutan perlu diarahkan pada pembangunan dataset ground truth untuk evaluasi dengan metrik information retrieval seperti Precision@K dan nDCG, perbandingan dengan baseline keyword matching, collaborative filtering, maupun model hybrid, serta pengujian dampak fitur terhadap completion rate dan retensi belajar dalam jangka menengah.

## UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada pihak kampus, pembimbing, dan seluruh responden yang telah mendukung proses pengembangan sistem serta pengujian fitur rekomendasi jalur belajar pada platform Genii.

## DAFTAR PUSTAKA

- [1] D. R. Bailey, N. Almusharraf, and A. Almusharraf, "Video conferencing in the e-learning context: Explaining learning outcome with the technology acceptance model," *Education and Information Technologies*, vol. 27, no. 6, pp. 7679-7698, 2022, doi: 10.1007/s10639-022-10949-1.
- [2] J. Barria-Pineda, "Exploring the need for transparency in educational recommender systems," in *Proc. 28th ACM Conf. User Modeling, Adaptation and Personalization*, 2020, pp. 376-379, doi: 10.1145/3340631.3398676.
- [3] V. Braun and V. Clarke, "Using thematic analysis in psychology," *Qualitative Research in Psychology*, vol. 3, no. 2, pp. 77-101, 2006, doi: 10.1191/1478088706qp063oa.
- [4] 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.
- [5] B. Celik and K. Cagiltay, "Uncovering MOOC completion: A comparative study of completion rates from different perspectives," *Open Praxis*, vol. 16, no. 3, pp. 445-456, 2024, doi: 10.55982/openpraxis.16.3.606.
- [6] Convex, "Vector search," Convex Developer Hub. Accessed: Apr. 10, 2026. [Online]. Available: <https://docs.convex.dev/search/vector-search>.
- [7] F. D. Davis, "Perceived usefulness, perceived ease of use, and user acceptance of information technology," *MIS Quarterly*, vol. 13, no. 3, pp. 319-340, 1989, doi: 10.2307/249008.
- [8] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, "BERT: Pre-training of deep bidirectional transformers for language understanding," in *Proc. NAACL-HLT 2019*, 2019, pp. 4171-4186, doi: 10.18653/v1/N19-1423.
- [9] B. Hollister, P. Nair, S. Hill-Lindsay, and L. Chukoskie, "Engagement in online learning: Student attitudes and behavior during COVID-19," *Frontiers in Education*, vol. 7, Art. no. 851019, 2022, doi: 10.3389/educ.2022.851019.
- [10] H. Huang, L. Jew, and D. Qi, "Take a MOOC and then drop: A systematic review of MOOC engagement pattern and dropout factor," *Heliyon*, vol. 9, no. 4, Art. no. e15220, 2023, doi: 10.1016/j.heliyon.2023.e15220.
- [11] D. R. Jovanka et al., "Determinants of e-learning services: Indonesian Open University," *Cogent Education*, vol. 10, no. 1, Art. no. 2183703, 2023, doi: 10.1080/2331186X.2023.2183703.
- [12] P. Lops, M. de Gemmis, and G. Semeraro, "Content-based recommender systems: State of the art and trends," in *Recommender Systems Handbook*, F. Ricci, L. Rokach, B. Shapira, and P. B. Kantor, Eds. Boston, MA, USA: Springer, 2011, pp. 73-105, doi: 10.1007/978-0-387-85820-3\_3.
- [13] B. Ma, M. Lu, Y. Taniguchi, and S. Konomi, "CourseQ: The impact of visual and interactive course recommendation in university environments," *Research and Practice in Technology Enhanced Learning*, vol. 16, no. 1, Art. no. 18, 2021, doi: 10.1186/s41039-021-00167-7.
- [14] J. A. Marquez Garcia, C. Gallego Gomez, A. Tapia Lopez, and M. J. Schlosser, "Applying the technology acceptance model to online self-learning: A multigroup analysis," *Journal of Innovation & Knowledge*, vol. 9, no. 4, Art. no. 100571, 2024, doi: 10.1016/j.jik.2024.100571.
- [15] J. C. Nunnally, *Psychometric Theory*, 2nd ed. New York, NY, USA: McGraw-Hill, 1978.
- [16] OpenAI, "Embeddings," OpenAI API Reference. Accessed: Apr. 10, 2026. [Online]. Available: <https://platform.openai.com/docs/guides/embeddings>.
- [17] K. Pliakos, S.-H. Joo, J. Y. Park, F. Cornillie, C. Vens, and W. Van den Noortgate, "Integrating machine learning into item response theory for addressing the cold start problem in adaptive learning systems," *Computers & Education*, vol. 137, pp. 91-103, 2019, doi: 10.1016/j.compedu.2019.04.009.
- [18] N. Reimers and I. Gurevych, "Sentence-BERT: Sentence embeddings using Siamese BERT-networks," in *Proc. EMNLP-IJCNLP 2019*, 2019, pp. 3982-3992, doi: 10.18653/v1/D19-1410.
- [19] S. S. Saleh, M. Nat, and M. Aqel, "Sustainable adoption of e-learning from the TAM perspective," *Sustainability*, vol. 14, no. 6, Art. no. 3690, 2022, doi: 10.3390/su14063690.

- [20] C. Troussas, A. Krouska, P. Tselenti, D. K. Kardaras, and S. Barbounaki, "Enhancing personalized educational content recommendation through cosine similarity-based knowledge graphs and contextual signals," *Information*, vol. 14, no. 9, Art. no. 505, 2023, doi: 10.3390/info14090505.
- [21] H. Yuan and A. A. Hernandez, "User cold start problem in recommendation systems: A systematic review," *IEEE Access*, vol. 11, pp. 136958-136977, 2023, doi: 10.1109/ACCESS.2023.3338705.
- [22] Y. Zheng and J. R. Toribio, "The role of transparency in multi-stakeholder educational recommendations," *User Modeling and User-Adapted Interaction*, vol. 31, pp. 513-540, 2021, doi: 10.1007/s11257-021-09291-x.
- [23] M. R. Waskito, A. D. Rahajoe, and A. L. Nurlaili, "Implementasi metode collaborative filtering menggunakan algoritma cosine similarity dan Jaccard similarity pada sistem e-commerce," *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 12, no. 3S1, pp. 4307-4313, 2024, doi: 10.23960/jitet.v12i3S1.5315.
- [24] A. A. M. Fani, W. Clarisha, N. A. E. Budiarti, and A. H. Nasrullah, "Forward chaining untuk rekomendasi buku bacaan berdasarkan minat pembaca," *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 13, no. 3, 2025, doi: 10.23960/jitet.v13i3.6656.